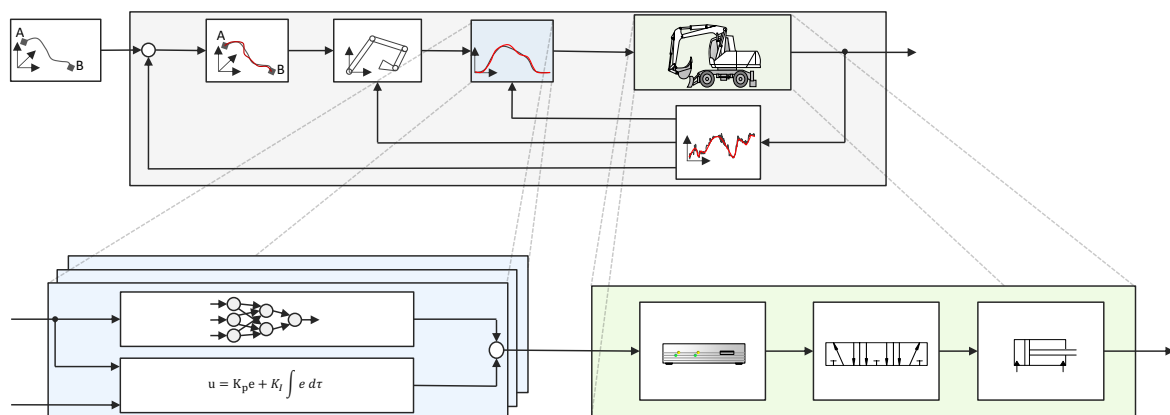


# DIPLOMARBEIT

## Einsatz von maschinellen Lernmethoden für die Automatisierung hydraulischer Baumaschinen



|                    |  |
|--------------------|--|
| Verfasser:         | cand. -Ing. Nico Zantopp                                 |
| Matrikelnummer:    | 385012   |
| Betreuer:          | Dr. Ozan Demir (Fa. Bosch)<br>M.Sc. Tatjana Legler (TUK) |
| Eingereicht bei:   | Prof. Dr.-Ing. Martin Ruskowski (TUK)                    |
| Nummer der Arbeit: | 2019-41  |
| Datum:             | 10. Dezember 2019  |

# Erklärung

Hiermit versichere ich, dass ich die vorliegende Arbeit selbständig verfasst und ohne unerlaubte, fremde Hilfe angefertigt habe. Alle Ausführungen, die anderen Schriften wörtlich oder sinngemäß übernommen wurden, sind kenntlich gemacht. Alle verwendeten Quellen sind im Literaturverzeichnis zitiert.

Kaiserslautern, den 10. Dezember 2019

*Zantopp, Nico*

Verfasser: Nico Zantopp

# Vorwort

Die vorliegende Arbeit entstand während meiner Tätigkeit als Diplomand in der Abteilung Applied Robotics for Offroad and Offshore bei der Firma Robert Bosch GmbH in Renningen. Für die Möglichkeit zur Durchführung meiner Diplomarbeit, die Bereitstellung der dafür nötigen Mittel und vor allem die weitreichende Unterstützung möchte ich mich herzlich bedanken.



# Inhaltsverzeichnis

|  |             |
|--|-------------|
| <b>Erklärung</b>   |             |
| <b>Vorwort</b>   |             |
| <b>Kurzfassung</b>   | <b>VIII</b> |
| <b>Abstract</b>  | <b>VIII</b> |
| <b>Symbolverzeichnis</b>   | <b>IX</b>   |
| <b>Abkürzungsverzeichnis</b>   | <b>X</b>    |
| <b>1 Einleitung</b>  | <b>1</b>    |
| 1.1 Problemstellung . . . . .  | 2           |
| 1.2 Zielsetzung . . . . .  | 3           |
| 1.3 Gliederung der Arbeit . . . . .  | 4           |
| <b>2 Stand der Technik</b>   | <b>6</b>    |
| 2.1 Grundstruktur von elektrohydraulischen Systemen . . . . .              | 7           |
| 2.2 Grundlegende Komponenten von hydraulischen Systemen . . . . .          | 8           |
| 2.2.1 Hydraulische Zylinder . . . . .                                      | 8           |
| 2.2.2 Proportionalventile . . . . .  | 10          |
| 2.3 Hydraulische Steueranordnungen . . . . .                               | 11          |
| 2.3.1 Load-Sensing Systeme . . . . .                                       | 11          |
| 2.3.2 Lastdruckunabhängige Durchflussverteilung . . . . .                  | 12          |
| 2.4 Einflussfaktoren bei der Regelung von hydraulischen Systemen . . . . . | 14          |
| 2.5 Versuchsträger . . . . .   | 15          |
| 2.5.1 Steuerung mit Hilfe von Joysticks . . . . .                          | 16          |
| 2.5.2 Automatisierung der Bewegung . . . . .                               | 17          |
| 2.5.3 Software Struktur: Assistenzfunktionen . . . . .                     | 18          |
| 2.5.4 Regelung der Zylindergeschwindigkeit . . . . .                       | 19          |
| 2.6 Signalverarbeitung . . . . .   | 20          |
| 2.6.1 Filter . . . . .   | 20          |

|          |  |           |
|----------|--|-----------|
| <b>3</b> | <b>Grundlagen der datenbasierten Modellierung</b>            | <b>23</b> |
| 3.1      | Problemformulierung . . . . .                                | 24        |
| 3.1.1    | Übersicht der Modellierungsansätze . . . . .                 | 26        |
| 3.2      | Vorgehensweise der datenbasierten Modellierung . . . . .     | 27        |
| 3.2.1    | Prozess der Identifikationsverfahrensauswahl . . . . .       | 27        |
| 3.3      | Neuronale Netze . . . . .                                    | 29        |
| 3.3.1    | Aufbau von Multi-Layer-Perceptrons . . . . .                 | 29        |
| 3.3.2    | Aktivierungsfunktionen . . . . .                             | 30        |
| 3.3.3    | Künstliche Neuronale Netzwerke . . . . .                     | 31        |
| 3.3.4    | Forward Propagation . . . . .                                | 32        |
| 3.3.5    | Training . . . . .   | 34        |
| 3.3.6    | Lernkurve . . . . .  | 35        |
| 3.4      | Methoden der Hyperparameteroptimierung . . . . .             | 38        |
| 3.4.1    | Grid search Optimierung . . . . .                            | 38        |
| 3.4.2    | Random search Optimierung . . . . .                          | 39        |
| 3.4.3    | Bayesian Optimierung . . . . .                               | 40        |
| <b>4</b> | <b>Versuchsplanung und Durchführung</b>                      | <b>42</b> |
| 4.1      | Versuchsplanung für datenbasierte Modellierung . . . . .     | 42        |
| 4.1.1    | Systemgrenzen . . . . .                                      | 44        |
| 4.1.2    | Festlegung der Abtastzeit . . . . .                          | 48        |
| 4.1.3    | Versuchsdurchführung . . . . .                               | 50        |
| 4.2      | Anregungssignale . . . . .                                   | 51        |
| 4.2.1    | Chirp . . . . .  | 52        |
| 4.2.2    | Amplitudenmoduliertes pseudo-random binäre Sequenz . . . . . | 52        |
| 4.2.3    | Sprunganregung . . . . .                                     | 54        |
| 4.3      | Datennachbearbeitung . . . . .                               | 55        |
| 4.3.1    | Ausreißer . . . . .  | 55        |
| 4.3.2    | Filterung der Trainingsdaten . . . . .                       | 56        |
| 4.4      | Vergleich der Messreihen . . . . .                           | 59        |
| 4.4.1    | Eingangs Ausgangskorrelation . . . . .                       | 60        |
| 4.4.2    | Verteilungen . . . . .                                       | 63        |
| <b>5</b> | <b>Modellbildung</b>   | <b>65</b> |
| 5.1      | Inverses Streckenmodell . . . . .                            | 65        |
| 5.2      | Abbildung der Dynamik . . . . .                              | 67        |
| 5.3      | Hyperparameter . . . . .                                     | 69        |
| 5.3.1    | Anzahl an Schichten . . . . .                                | 69        |
| 5.3.2    | Neuronenanzahl . . . . .                                     | 70        |

|           |   |           |
|-----------|---|-----------|
| 5.3.3     | Wahl der Aktivierungsfunktionen . . . . .                         | 70        |
| 5.4       | Strukturprüfung durch Auswahl signifikanter Regressoren . . . . . | 70        |
| 5.4.1     | Kennzahlen der Modellgüte . . . . .                               | 71        |
| 5.4.2     | Ergebnisse der Strukturprüfung . . . . .                          | 72        |
| 5.5       | Ergebnisse . . . . .  | 74        |
| 5.5.1     | Resultat der Optimierung . . . . .                                | 74        |
| 5.5.2     | Lernkurve . . . . .   | 75        |
| 5.5.3     | Ergebnisse auf dem Crossvalidierungsdatensatz . . . . .           | 76        |
| <b>6</b>  | <b>Validierung</b>  | <b>78</b> |
| 6.1       | Physikalisch modellierter Regler . . . . .                        | 79        |
| 6.2       | Einzelachsbewegung . . . . .                                      | 80        |
| 6.2.1     | Kleine Geschwindigkeiten . . . . .                                | 80        |
| 6.2.2     | Mittlere und große Geschwindigkeiten . . . . .                    | 81        |
| 6.3       | Mehrachsbewegung mit externer Last . . . . .                      | 83        |
| 6.3.1     | Ergebnisse beim Planieren . . . . .                               | 84        |
| <b>7</b>  | <b>Fazit</b>  | <b>86</b> |
| <b>A1</b> | <b>Ergebnisse Modellierung Stielzylinder</b>                      | <b>88</b> |
| A1.1      | Daten . . . . .   | 88        |
| A1.2      | Netzstruktur . . . . .  | 88        |
| A1.3      | Modellperformance . . . . .                                       | 89        |
|           | <b>Literaturverzeichnis</b>                                       | <b>91</b> |

# Abbildungsverzeichnis

|      |   |    |
|------|---|----|
| 1.1  | Vereinfachte Darstellung der Strecke eines Baggers . . . . .  | 2  |
| 1.2  | Regelung der Strecke . . . . .  | 3  |
| 1.3  | Methodik der Arbeit . . . . .   | 4  |
| 2.1  | Grundlegender Aufbau eines Mobilbaggers . . . . .   | 6  |
| 2.2  | Schematische Darstellung der Grundstruktur von hydraulischen Systemen . . . . .                               | 7  |
| 2.3  | Hydraulische Zylinder a) einfach wirkend b) asymmetrisch doppelwirkend c) symmetrisch doppelwirkend . . . . . | 9  |
| 2.4  | Load-Sensing (LS) System . . . . .  | 12 |
| 2.5  | Lastdruckunabhängige Durchflussverteilung (LUDV) System . . . . .   | 13 |
| 2.6  | Übersicht der Einflussfaktoren bei der Entwicklung einer Regelstrategie für hydraulische Systeme . . . . .    | 14 |
| 2.7  | Versuchsträger <i>JCB Hydradig</i> . . . . .  | 15 |
| 2.8  | Belegung der Joysticks eines Baggers . . . . .  | 16 |
| 2.9  | Überlagerte Software Struktur für das autonome Baggen . . . . .   | 18 |
| 2.10 | Geschwindigkeitsregler mit physikalischem Modell . . . . .  | 19 |
| 2.11 | Frequenzgang der unterschiedlichen Filtertypen . . . . .  | 20 |
| 2.12 | Bode-Diagramm für einen Filter erster Ordnung . . . . .   | 21 |
| 3.1  | Ansätze zur Modellierung von dynamischen Systemen . . . . .   | 23 |
| 3.2  | Modellstrukturen für die Beschreibung von dynamischen Systemen . . . . .                                      | 26 |
| 3.3  | Iterativer Prozess zur Auswahl des besten Modells . . . . .   | 28 |
| 3.4  | Künstliches Neuron mit 3 Eingängen . . . . .  | 29 |



|      |  |    |
|------|--|----|
| 3.5  | Aktivierungsfunktionen . . . . .   | 31 |
| 3.6  | Neuronales Netzwerk mit einer verdeckten Schicht . . . . .                     | 32 |
| 3.7  | Lernkurve . . . . .  | 36 |
| 3.8  | Darstellung der möglichen Anpassungen des Modells . . . . .                    | 36 |
| 3.9  | Darstellung der Lernkurven für die möglichen Anpassungen des Modells . . . . . | 37 |
| 3.10 | Hyperparameteroptimierung mit Hilfe von dem Grid search Verfahren . . . . .    | 39 |
| 3.11 | Hyperparameteroptimierung mit Hilfe von dem Random search Verfahren . . . . .  | 39 |
| 3.12 | Modell der Bayesian Optimierung . . . . .                                      | 40 |
| 4.1  | Blockschaltbild Datengenerierung . . . . .                                     | 43 |
| 4.2  | Mögliche Art der Signalgenerierung . . . . .                                   | 43 |
| 4.3  | Geschwindigkeitsverlauf bei Planziehbewegungen . . . . .                       | 46 |
| 4.4  | Fourier-Transformation der Joysticksignale bei Planziehbewegungen . . . . .    | 47 |
| 4.5  | Arbeitsraumbegrenzung . . . . .  | 48 |
| 4.6  | Amplitudenspektrum der Geschwindigkeit . . . . .                               | 49 |
| 4.7  | Unterteilung Arbeitsbereich . . . . .  | 51 |
| 4.8  | Sprungantwort Auslegerzylinder . . . . .                                       | 54 |
| 4.9  | Behebung von Ausreißern . . . . .  | 56 |
| 4.10 | Grundstruktur für die Filterung der Daten . . . . .                            | 56 |
| 4.11 | Fourier-Transformation des LS-Drucksignals . . . . .                           | 57 |
| 4.12 | Numerische Ableitung des ungefilterten Positionssignals . . . . .              | 58 |
| 4.13 | Vergleich Finite impulse response (FIR)- und PT1-Filter . . . . .              | 59 |
| 4.14 | Applizierte Signale zur Datengenerierung . . . . .                             | 59 |
| 4.15 | Legende für die Streudiagramme . . . . .                                       | 60 |
| 4.16 | Korrelation der Geschwindigkeit mit dem Joysticksignal . . . . .               | 60 |
| 4.17 | Korrelation der Blendendruckdifferenz mit dem Joysticksignal . . . . .         | 61 |
| 4.18 | Korrelation der Zylinderdruckdifferenz mit dem Joysticksignal . . . . .        | 62 |

|      |  |    |
|------|--|----|
| 4.19 | Verteilungen der Joysticksignale . . . . .   | 63 |
| 5.1  | Training des Neuronalen Netzes . . . . .   | 66 |
| 5.2  | Externe Dynamik des Modells . . . . .  | 68 |
| 5.3  | Vergleich von der Regressoren . . . . .  | 73 |
| 5.4  | Optimierungskurve des inversen datenbasierten Streckenmodells für den Auslegerzylinder . . . . . | 74 |
| 5.5  | Lernkurve des inversen datenbasierten Streckenmodells für den Auslegerzylinder .                 | 75 |
| 5.6  | Performance des Neuronalen Netzes auf dem Crossvalidierungsdatensatz . . . . .                   | 76 |
| 6.1  | Blockschaltbild Reglerstruktur . . . . .   | 78 |
| 6.2  | Modellstruktur des Kennfelds . . . . .   | 79 |
| 6.3  | Erzeugung der Solltrajektorie für den Einzelachsreglertest . . . . .                             | 80 |
| 6.4  | Regelverhalten bei kleinen Geschwindigkeiten . . . . .   | 81 |
| 6.5  | Regelverhalten bei mittleren und großen Geschwindigkeiten . . . . .                              | 82 |
| 6.6  | Überlagerte Reglerstruktur für autonome Bewegungen . . . . .                                     | 83 |
| 6.7  | Bewegung des Tool Center Point (TCP)s bei dem Mehrachsreglertest . . . . .                       | 84 |
| 6.8  | Geschwindigkeitsverlauf Planziehbewegung beim Reglertest . . . . .                               | 85 |
| A1.1 | Streudiagramme des Trainingsdatensatzes für den Stielzylinder . . . . .                          | 88 |
| A1.2 | Lernkurve des inversen datenbasierten Streckenmodells für den Auslegerzylinder .                 | 89 |

# Tabellenverzeichnis

|      |  |    |
|------|--|----|
| 3.1  | Übersicht der Aktivierungsfunktionen . . . . .                             | 30 |
| 4.1  | Eingangslimitierung des Joysticksignals bei der Datengenerierung . . . . . | 45 |
| 5.1  | Überblick der Modellstrukturen . . . . .                                   | 67 |
| 5.2  | Gemessene Größen für einen Zylinder . . . . .                              | 71 |
| 5.3  | Ergebnisse der Hyperparameteroptimierung . . . . .                         | 75 |
| 5.4  | Ergebnisse auf dem Crossvalidierungsdatensatz . . . . .                    | 77 |
| A1.1 | Ergebnisse der Hyperparameteroptimierung für den Stielzylindern . . . . .  | 89 |
| A1.2 | Ergebnisse auf dem Crossvalidierungsdatensatz (Stielzylinder) . . . . .    | 90 |

# Kurzfassung

Eine grundlegende Voraussetzung für die Entwicklung von teilautonomer hydraulischen Maschinen ist die automatisierte Bewegung der notwendigen Strukturen. Die Anforderungen an diese Bewegungen sind hoch und aus diesem Grund sind einfache Reglerstrukturen ohne konkrete Streckenkenntnis nicht ausreichend. Die Beschreibung des Streckenkennmodells ist bei hydraulischen Maschinen sehr komplex und zeitaufwendig. Die Modellierung mit theoretischen auf physikalischen Ansätzen beruhenden Methoden ist daher unwirtschaftlich. Aufgrund dessen müssen für die Entwicklung von teilautonomen Maschinen alternative Strategien zur Beschreibung der Dynamik entwickelt werden. Im Rahmen der Diplomarbeit wurde die Machbarkeit von Neuronalen Netzen zur modellbasierten Geschwindigkeitsregelung von hydraulischen Zylindern an einem Bagger untersucht. Dabei wurden unterschiedliche Anregungssignale überprüft und das Regelverhalten des Neuronalen-Reglers auf einem realen Versuchsträger verifiziert. Es hat sich gezeigt, dass sich die datenbasierten Methoden zur Regelung von elektrohydraulischen Baggern eignen. Im Vergleich zu theoretischen Ansätzen konnte eine Steigerung der Regelgüte, bei gleichzeitiger Reduzierung des Arbeitsaufwandes von mehreren Monaten hinzu wenigen Tagen, erreicht werden.

# Abstract

A fundamental prerequisite for the development of semi-autonomous hydraulic machines is the automated movement of the necessary structures. The requirements for these movements are high and for this reason, simple control structures without concrete knowledge of the plant behavior are not sufficient. The description of the plant model for hydraulic machines is very complex and time-consuming. Modeling with theoretical methods based on physical approaches is therefore uneconomical. Therefore, alternative strategies for the description of dynamics have to be used for the development of semi-autonomous machines. Within the diploma thesis, the feasibility of neural networks for model-based speed control of hydraulic cylinders on an excavator was investigated. Different excitation signals were tested and the control behavior of the neural controller was verified on a real test vehicle. It has been shown that the data-based methods are suitable for the control of electrohydraulic excavators. In comparison to theoretical approaches, an increase in the control quality could be achieved, while at the same time reducing the workload by several months to a few days.

# Symbolverzeichnis

*Selten benutzte Formelzeichen und Begriffe sowie abweichende Bedeutungen werden ausschließlich im Text erläutert.*

## Lateinische Notation

|                 |                             |
|-----------------|-----------------------------|
| $p_{Hd}$        | Kopfdruck Zylinder          |
| $p_{Rd}$        | Pleuedruck Zylinder         |
| $\delta p$      | Druckdifferenz              |
| $p_{Pmp}$       | Pumpendruck                 |
| $p_{LS}$        | Lastdruck                   |
| $J_{stk}$       | Joysticksignal              |
| $s$             | Zylinderposition            |
| $\dot{s}_{des}$ | Sollzylindergeschwindigkeit |
| $\dot{s}$       | Zylindergeschwindigkeit     |
| $\ddot{s}$      | Zylinderbeschleunigung      |
| $T_F$           | Zeitkonstante Filter        |
| $u$             | Eingang                     |
| $y$             | Ausgang                     |
| $x$             | Zustand des Systems         |
| $w$             | Gewichtung, Gewicht         |
| $T_s$           | Sample Zeit                 |
| $o$             | Ausgang Neuron bzw. Schicht |
| $net$           | Eingang Neuron bzw. Schicht |
| $T_M$           | Messzeit                    |
| $G$             | Übertragungsfunktion        |

## Griechische Notation

|           |                |
|-----------|----------------|
| $\phi$    | Regressor      |
| $\lambda$ | Hyperparameter |

# Abkürzungsverzeichnis

|              |  |
|--------------|--|
| <b>LUDV</b>  | Lastdruckunabhängige Durchflussverteilung          |
| <b>TCP</b>   | Tool Center Point                                  |
| <b>LS</b>    | Load-Sensing                                       |
| <b>RCP</b>   | Rapid-Control-Prototyping                          |
| <b>APRBS</b> | Amplitudenmoduliertes pseudo-random binäre Sequenz |
| <b>CAN</b>   | Controller Area Network                            |
| <b>RMSE</b>  | Root Mean Square Error                             |
| <b>MSE</b>   | Mean Square Error                                  |
| <b>MAE</b>   | Mean absolute error                                |
| <b>MLP</b>   | Multilayer Perceptrons                             |
| <b>MAD</b>   | Median Absolute Deviation                          |
| <b>NN</b>    | Neuronales Netz                                    |
| <b>LSTM</b>  | Long-Short-Time-Memory                             |
| <b>LM</b>    | Levenberg–Marquardt                                |
| <b>FIR</b>   | Finite impulse response                            |

# 1 Einleitung

Systeme mit Assistenzfunktion sind heute bereits in vielen Anwendungsfeldern verbreitet. Die vielfältigen Einsatzbereiche sind beispielsweise neben der Produktion und dem Mobilitätsbereich, Wohn- und Zweckgebäude (Smart Home bzw. Smart Building) auch der Energie-, Bau-, Landwirtschafts- und Gesundheitssektor [DUM18]. Ein Einsatzbereich aus dem Bausektor ist der Sektor der hydraulischen Arbeitsmaschinen, an deren Automatisierung seit mehreren Jahren geforscht wird [HEMA09]. Hintergrund stellt die Komplexität der Bedienung und der Aspekt des immer stärkeren Fachkräftemangels in der Bauwirtschaft dar [BAUM16]. Gerade die Steuerung von Baggern ist schwer zu erlernen, da die Position der Schaufel indirekt über ein mindestens zweigliedriges Getriebe eingestellt werden muss [LORE17]. Für eine präzise und gleichzeitig schnelle Operation sind jahrelange Erfahrungen notwendig. Einen Forschungs- und Entwicklungsschwerpunkt bildet hierbei die Übertragung von fortschrittlichen Methoden der Robotik und der künstlichen Intelligenz auf hydraulische Arbeitsmaschinen. Wie in [ROBE02] dargestellt, führt der Weg zur vollständigen Automatisierung zunächst über die Entwicklung von Assistentenfunktionen, bei denen der Operator nur die Aufgabe der Überwachung und Freigabe des Prozesses hat. Die Entwicklung neuer Assistentenfunktionen für Bagger erlaubt es auch ungeübten Operatoren komplexe und präzise Bewegungen durchzuführen. Aufgrund der geringeren Anforderungen an den Operator führt dies zu einer Reduzierung der Arbeitsbelastung [BRAD98]. Aus wirtschaftlicher Sicht kann dadurch die Maschinennutzung und der Durchsatz gesteigert werden, wodurch es zu einer Steigerung der Rentabilität kommt [SCHM10].

Eine grundlegende Voraussetzung für die Entwicklung von Assistenzfunktionen und teilautonomer Maschinen ist die automatisierte Bewegung der für Prozessbearbeitung notwendigen Strukturen. Um dies zu erreichen müssen neben geeigneten Sensorprinzipien zur Erfassung der Ist-Position der Schaufel auch entsprechende Regelstrategien implementiert werden. Diese haben die Aufgabe aus der berechneten Regelabweichung geeignete Ansteuersignale zur Umsetzung der gewünschten Positions- oder Geschwindigkeitstrajektorie zu generieren. Da erfahrene Baggerfahrer Trajektorien sehr präzise und schnell abfahren können, sind die Anforderungen an die Automatisierungsfunktionen entsprechend hoch. Einfache Reglerstrukturen ohne konkrete Streckenkenntnis können diese Anforderungen nicht erfüllen. Aus diesem Grund wird die Streckenkenntnis oft für eine modellbasierte Regelung eingesetzt, um die geforderte Performance zu erreichen [CHAC14].

## 1.1 Problemstellung

Um die modellbasierte Regelung anzuwenden ist eine konkrete Streckenkenntnis notwendig. Eine Regelstrecke wird in erster Linie durch ihr Zeitverhalten – die Streckendynamik - charakterisiert [LUNZ16]. Sie besteht aus einer Kette von Einzelsystemen und bildet den Teil eines Regelkreises. Das Streckenverhalten und der Regler des Baggers lässt sich vereinfacht wie in Abb. 1.1 dargestellt beschreiben.




Abbildung 1.1: Vereinfachte Darstellung der Strecke eines Baggers

Die Beschreibung des Streckenverhaltens ist komplex. Bei der dargestellten Strecke handelt es sich um eine Strecke in mehreren Domänen, beispielsweise treten in dem System hydraulische, mechanische und elektrische Vorgänge auf. Neben diesem Aspekt besitzen die einzelnen Domänen auch ein nichtlineares Verhalten, welches nicht einfach zu beschreiben ist. Soll nun wie in Abb. 1.1 gezeigt, ein inverses Streckenmodell als Vorsteuerung eingesetzt werden, ist es notwendig das inverse Verhalten zu modellieren. Hierfür kommen meist theoretische (auf physikalischen Ansätzen beruhende) Methoden zum Einsatz. Diese Methoden sind für solche komplexen Systeme jedoch sehr zeitaufwändig und erfordern detaillierte Informationen der einzelnen verbauten Komponenten.

Gerade im Bereich von hydraulischen Baumaschinen kommt es zu Herausforderungen bei dem Einsatz von theoretischen Ansätzen, welche einen großen zeitlichen Aufwand mit sich ziehen. Beispielsweise kann es bei der Entwicklung von hydraulischen Baumaschinen vorkommen, dass nicht alle hydraulischen Bauteile von einem Hersteller sind und dadurch die exakten Daten und Eigenschaften der einzelnen Komponenten nicht bekannt sind. Diese fehlenden Informationen erschweren eine genaue physikalische Modellierung. Um ein hinreichend genaues Streckenmodell zu erzeugen müssen hierfür die fehlenden Informationen der Komponenten entweder abgeschätzt oder durch aufwendige Tests bestimmt werden. Zudem besitzen hydraulische Komponenten große Produktionstoleranzen, wodurch sich das Verhalten von gleichen Komponenten unterscheiden kann. Der Markt von hydraulischen Maschinen setzt sich aus einer Low-Volume-High-Mix-Fertigung zusammen. Das bedeutet, dass die Stückzahlen gering und die Varianz bei den Baggern hoch ist. Dies macht das Verhalten von jedem Bagger einzigartig, sodass eine genaue Übertragbarkeit von Modellen nicht gegeben ist. Diese Marktzusammensetzung und der zeitliche hohe Aufwand für die Modellierung eines einzelnen Baggers machen den Einsatz von theoretischen Ansätzen unwirtschaftlich [SCHM10].



Es notwendig alternative Methoden einzusetzen, um eine wirtschaftliche Lösung der Modellierung des Verhaltens zu schaffen. In den letzten Jahren hat sich gezeigt, dass die datenbasierten Ansätze eine interessante Möglichkeit darstellen, da diese eine präzise Approximation des Systemverhaltens ermöglichen ohne die Eigenschaften der verbauten Bauteile zu kennen [NGUY11]. Außerdem bieten diese auch den Vorteil, im Vergleich zu physikalisch basierten Modellierungsansätzen, auch unbekannte Nichtlinearität abbilden zu können [WANG11].

Die Abb. 1.2 verdeutlicht den Ansatz der datenbasierten Methoden. Es ist in dem Blockdiagramm zu sehen, dass das datenbasierte Modell direkt das inverse Streckenverhalten abbilden soll.

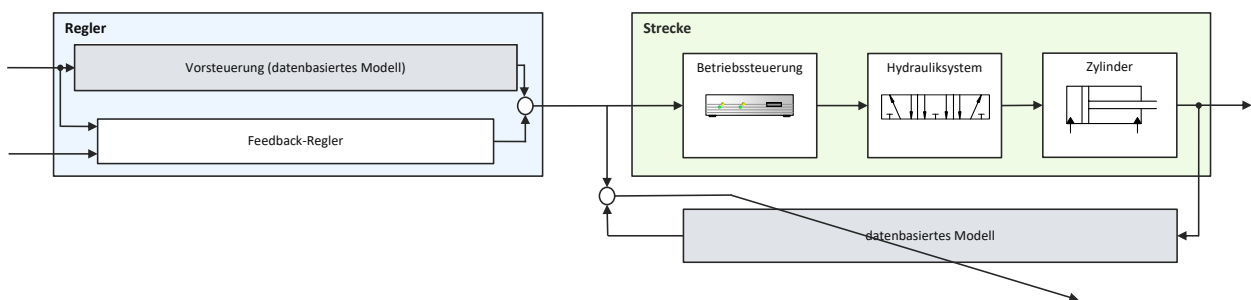


Abbildung 1.2: Regelung der Strecke

Nachdem das Modell erstellt wurde kann es wie in der Abb. 1.2 zu sehen direkt in dem Regler eingesetzt werden. Mit diesem Ansatz kann der Modellierungsaufwand deutlich reduziert werden. Es müssen lediglich für jeden Bagger neue Trainingsdaten generiert und anschließend das Modell trainiert werden. Eine genaue Kenntnis über die verbauten Teile und auftretenden Effekte muss nicht individuell untersucht werden. Die Trainingsdaten könnten beispielsweise direkt bei der End-of-Line Kalibrierung von hydraulischen Maschinen aufgenommen werden. Diese datenbasierten Methoden haben das Potential eine Marktdurchdringung von modellbasierten Regelungen herbeizuführen, und so für preisgünstige Maschinen Assistenzfunktionen bereitzustellen.

## 1.2 Zielsetzung

Ziel der Arbeit ist ein Nachweis der Machbarkeit (Proof of Concept) von datenbasierten Methoden zur Regelung der Geschwindigkeit von hydraulischen Zylindern. Diese soll nicht nur theoretisch oder anhand einer Simulation erbracht werden, sondern an einem realen Versuchsträger. In dieser Arbeit wird davon ausgegangen, dass das System unbekannt ist. Der Nachweis der Machbarkeit soll zunächst an einer einzelnen Achse untersucht werden. Als Versuchsträger wird ein Mobilbagger der Marke JCB mit einem Gewicht von 12 t eingesetzt. Stellt sich die Machbarkeit des datenbasierten Ansatzes für hydraulische Baumaschinen heraus so gilt es herauszufinden welche Daten für die Modellierung notwendig sind.

Die Daten spielen für die Güte des späteren Modells eine entscheidende Grundvoraussetzung. Im Rahmen der Arbeit sollen daher unterschiedliche Testsignale untersucht werden. Bei der Applikation dieser Testsignale ist der Datenaufwand und die Übertragbarkeit auf andere Bagger zu berücksichtigen.

Die verwendete Methodik zur Lösung der Forschungsfrage lässt sich in sechs Schritte aufteilen. In Abb. 1.3 sind die einzelnen Schritte der verwendeten Methodik dargestellt. Das Vorgehen umfasst die Versuchsplanung, Datengenerierung und Vorbereitung, die Modellbildung, die Validierung des Modells, den Reglertest und die Reglerverifikation- und Optimierung.

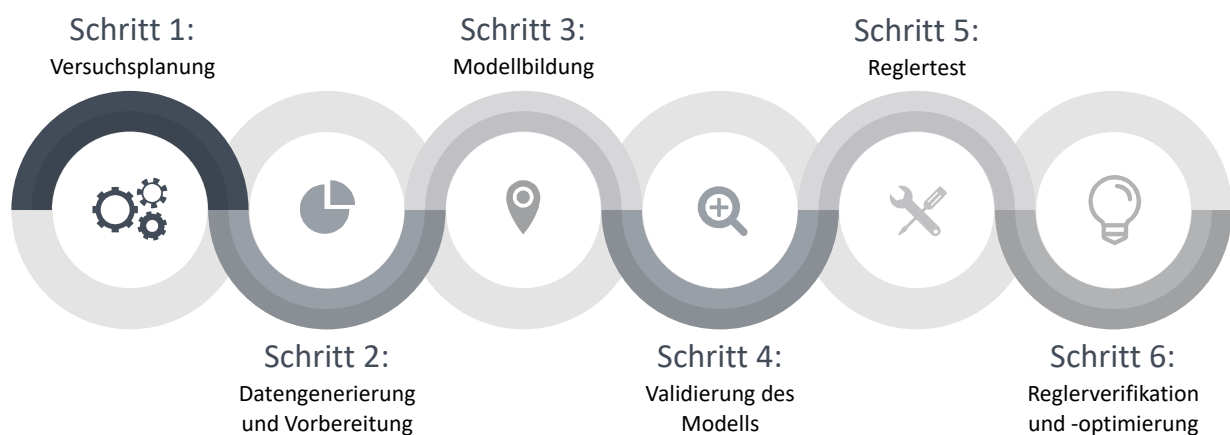


Abbildung 1.3: Methodik der Arbeit

Die Schritte eins und zwei aus der Abbildung umfassen die Datengenerierung. Im Rahmen der Datengenerierung werden Felduntersuchungen an einem realen Versuchsträger durchgeführt. Die hierbei aufgenommenen Daten werden aufbereitet und in der darauffolgenden Modellbildung (Schritt drei) verwendet. Das erstellte Modell wird in dem Schritt vier offline mit Hilfe von Validierungsdaten überprüft und bewertet. Wie in der Abb. 1.3 gezeigt befassen sich die letzten beiden Schritte (vier und fünf) mit der Prüfung des Reglers. Im Rahmen dieser Untersuchung wird das im Schritt drei erzeugte Modell in dem modellbasierten Regler verwendet und auf dem Versuchsträger untersucht. Und im sechsten Schritt wird der Regler optimiert.

## 1.3 Gliederung der Arbeit

Die Gliederung der Arbeit nimmt Bezug auf die dargestellte Methodik. Bevor jedoch näher auf die Lösung der einzelnen Schritte der Methodik eingegangen wird, geht die Arbeit zunächst auf die notwendigen Grundlagen der Hydraulik und modellbasierten Methoden ein. In Kapitel 2 wird der Forschungsstand bei der Automatisierung von Baggerbewegungen erläutert. Kapitel 3 geht auf die Grundlagen und genutzten Methoden zur Optimierung und das Training der Modelle ein. Der Fokus im Bereich der datenbasierten Methoden liegt hierbei auf Neuronalen Netzen.


Die Versuchsplanung, Aufbereitung der Daten und die Analyse im Sinne der Aufgabenstellung wird in dem Kapitel 4 dargestellt. Die in Kapitel 4 beschriebenen Daten werden in dem Kapitel 5 zur Modellierung des datenbasierten inversen Streckenverhaltens eingesetzt. Das Kapitel: Modellbildung geht auf die zu wählenden Parameter ein und zeigt die Validierung des Modells. Eine wichtige Untersuchung der Modellbildung ist die durchgeführte Regressorenstudie, welche die spätere Sensorkonfiguration in der Anwendung bestimmt.

Das darauffolgende Kapitel befasst sich mit der Validierung des Reglers. Im Rahmen dieser Untersuchung wird das in Kapitel 5 erzeugte Modell in dem modellbasierten Regler verwendet und auf dem Versuchsträger untersucht. Die Darstellung dieser Ergebnisse ist in Kapitel 6 zu finden.

## 2 Stand der Technik

Bereits seit 180 Jahren stellen Bagger ein wichtiges Werkzeug für die Bau-, Landwirtschaft- und Rohstoffindustrie dar. Zu Beginn erfolgte die Steuerung der Bagger über Seilwinden. Erst mit dem Beginn der Serienproduktion von Hydraulikbaggern vor 50 Jahren wurden die Seilbagger von den hydraulisch angesteuerten Baggern abgelöst. Durch die Vorzüge der Hydrostatik bei der Leistungsübertragung und -wandlung sind die Bagger leistungsfähiger geworden und können höhere Nutzlasten, Grabkräfte und Bewegungsgeschwindigkeiten bieten. [KUNZ02]

Bagger gehören zur Klasse der mobilen Arbeitsmaschinen und Erdbaumaschinen. Mobile Arbeitsmaschinen lassen sich nach Geimer und Pohlandt wie folgt definieren: *Mobile Arbeitsmaschinen haben die Aufgabe der Verrichtung eines Arbeitsprozesses. Sie verfügen dazu über einen Fahr- und Arbeitsantrieb mit signifikanten Energieanteilen in beiden Antrieben* [GEIM14]. Die Abb. 2.1 zeigt den grundlegenden Aufbau eines Mobilbaggers.



Quelle: Rose17

Abbildung 2.1: Grundlegender Aufbau eines Mobilbaggers

Ein Mobilbagger besitzt wie in der Abb. 2.1 zu erkennen Reifen anstatt Raupen. Das Fahrwerk<sup>⑧</sup> und der Unterwagen<sup>⑩</sup> werden durch das Drehwerk<sup>⑨</sup> verbunden. Das Drehwerk hat die Aufgabe den Oberwagen zu rotieren um dadurch den Arbeitsraum zu erweitern. Die Position der Schaufel<sup>⑪</sup> wird über mehrere hydraulische Zylinder gesteuert. Diese Zylinder werden von einem hydrau-

lischen System geregelt. Bei herkömmlichen Erdarbeiten wird der Baggerarm mit Hilfe des Auslegerzylinders ③, Stielzylinders ② und Löffelzylinders ① bewegt. Das hydraulische System kann sehr unterschiedlich sein. Aufgrund der hohen Varianz bei mobilen Arbeitsmaschinen gibt es eine große Anzahl von hydraulischen Bauweisen [KAUT14]. Daher kann an dieser Stelle der Arbeit nur auf die notwendigen Grundlagen für den verwendeten Versuchsträger eingegangen werden. In den folgenden Abschnitten wird zunächst auf die physikalischen Grundlagen der Komponenten sowie der Kreisläufe eingegangen und anschließend der Stand der Technik für das teilautonome Baggern dargestellt. Für eine tiefere Beschreibung von elektro-hydraulischen Komponenten und Kreisläufen kann [FINZ11, KUNZ02, MURR12] herangezogen werden.

## 2.1 Grundstruktur von elektrohydraulischen Systemen

Alle elektrohydraulisch angetriebenen mobilen Arbeitsmaschinen besitzen die gleiche hydraulische Grundstruktur. Diese lässt sich in die drei Hauptbereiche Versorgung, Regelung und Aktoren unterteilen. In dem Abb. 2.2 sind die drei genannten Bereiche schematisch dargestellt. Es zeigt den grundlegenden Aufbau eines elektrohydraulischen Systems mit zwei ventilgesteuerten Aktoren.

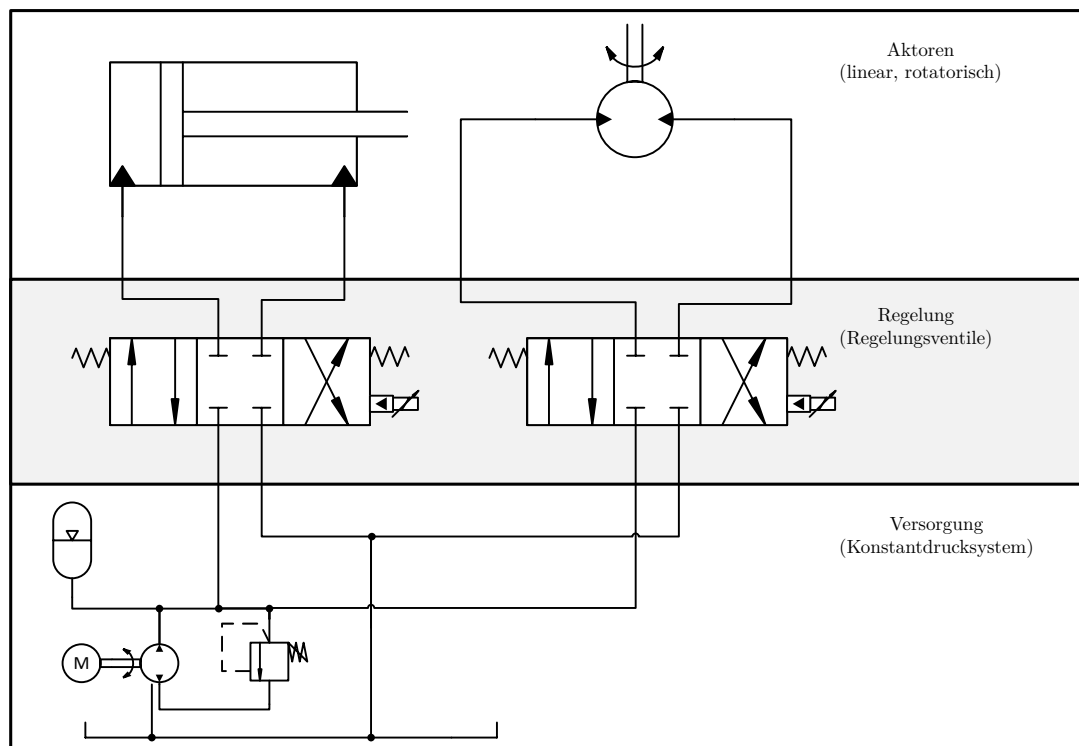


Abbildung 2.2: Schematische Darstellung der Grundstruktur von hydraulischen Systemen

Für den Betrieb von hydraulischen Systemen ist es notwendig, dass die für die Aktoren und Regelung notwendige Energie von der Versorgung bereitgestellt wird [WATT17]. Die Versorgung der Verbraucher wird in der beispielhaften Abb. 2.2 mit einer hydraulischen Pumpe umgesetzt welche

von einem Motor angetrieben wird. Die Pumpe wandelt die mechanische Energie des Motors in hydraulische Energie für das System. Wie in der Abbildung zu entnehmen wird für zwei Aktoren eine einzelne Pumpe eingesetzt. Dieser Aufbau ist auch in vielen mobilen Arbeitsmaschinen wiederzufinden [KUNZ02]. Bei diesen wird meist eine zentrale Pumpe direkt von einem Dieselmotor angetrieben.

Die von der Versorgung des hydraulischen Systems bereitgestellte Energie wird der Regeleinrichtung zugespeist. Diese Regelung kann bei servohydraulischen Antrieben als Geschwindigkeitsregelkreise, Lageregelkreise oder Kraftregelkreise umgesetzt werden [MURR12]. Dabei entscheidet die auszuführende Aufgabe der Aktoren über die Wahl der Regelung.

Wie in der Abb. 2.2 zu sehen kommt bei dem Beispiel ein Proportionalventil zum Einsatz. Das Ventil drosselt den von der Pumpe bereitgestellten Volumenstrom und steuert dadurch die Aktoren an. Die Regelung mit Hilfe von Proportionalventilen besitzt ausgezeichnete dynamische Eigenschaften, jedoch aufgrund von Verlusten eine geringe Energieeffizienz [WEIS95]. Diese signifikanten Verluste sind auf das dissipative Verhalten der Ventile zurückzuführen, welches auch als hydraulischen Widerstand angesehen werden kann [KOMS13].

Der dritte Bereich von elektrohydraulischen Systemen bilden die Aktoren. Die Aktoren haben die Aufgabe hydraulische Energie in mechanische Energie zu wandeln. Wie in der Abb. 2.2 zu sehen, kann zwischen linearen und rotatorischen Aktoren unterschieden werden. In hydraulischen Baumaschinen kommen am häufigsten lineare Aktoren zum Einsatz [KUNZ02]. Diese werden je nach Anwendungsfall durch die Regeleinrichtung angesteuert. Beispielsweise kann es notwendig sein, den hydraulischen Zylinder möglichst genau an eine Sollposition zu bewegen.

## **2.2 Grundlegende Komponenten von hydraulischen Systemen**

Dieser Abschnitt geht näher auf die grundlegenden Komponenten von hydraulischen Systemen ein. Die Grundlagen der Komponenten und die Interaktion innerhalb von hydraulischen Systemen sind für die spätere Modellierung und Entwicklung der Regelstrategie notwendig [KOMS13]. Nachfolgend werden die Grundlagen von hydraulischen Arbeitszylindern und Proportionalventilen kurz beschrieben.

### **2.2.1 Hydraulische Zylinder**

Hydraulische Zylinder sind die am häufigsten verwendeten linearen Aktoren in hydraulischen Systemen [KOMS13]. Sie haben die Aufgabe hydraulische Energie in lineare Bewegung oder Kräfte umzuwandeln.

Die Abb. 2.3 zeigt die drei am häufigsten verwendeten Zylindertypen. Es kann hierbei zwischen einfach- und doppelwirkenden Zylindern unterschieden werden. Die einfachwirkenden Zylinder können nur in eine Richtung durch die hydraulischen Kräfte bewegt werden. Die Retraktion des Zylinders kann nur durch externe Kräfte eingeleitet werden [WILL15].




Abbildung 2.3: Hydraulische Zylinder a) einfach wirkend b) asymmetrisch doppelwirkend c) symmetrisch doppelwirkend

Im Gegensatz zu den einfachwirkenden Zylindern können die doppelwirkenden Zylinder in zwei Richtungen bewegt werden. In Baggern sind häufig die doppelwirkenden Differentialzylinder zu finden [KUNZ02]. Diese Zylinder haben zwei Kammern (vgl. Abb. 2.3 b). Der Druck in der Kopfkammer wird nachfolgend als Kopfdruck  $p_{Hd}$  und der Druck in der Pleuelkammer als Pleueldruck  $p_{Rd}$  bezeichnet. Bei symmetrischen Zylindern ist die Fläche des Kolbens in beiden Kammern gleich, bei asymmetrischen Zylindern ist die Fläche auf der Kopfseite größer als die Fläche auf der Pleulseite. Dadurch entsteht ein asymmetrisches dynamisches Verhalten der hydraulischen Zylinder [WATT17]. Diese asymmetrische Dynamik erhöht die Komplexität bei der Regelung der Achszylinder: einerseits aufgrund der höheren Komplexität bei der Modellierung des Verhaltens, andererseits auch bei Optimierung von den Regelparametern für Extraktion und Retraktion des Zylinders [MURR12, KOMS13]. Die Komplexität ist aufwendig mit theoretischen (auf physikalischen Grundlagen beruhenden) Methoden zu modellieren. Bei den datenbasierten Methoden spielt diese interne Komplexität keine Rolle.

### Physikalische Grundlagen Arbeitszylinder

Bei dem Einsatz von mobilen Arbeitsmaschinen ist es notwendig, dass sich jeder einzelne Achszylinder in seiner Geschwindigkeit regulieren lässt [KUNZ02]. Die Geschwindigkeit eines translatorischen Achszylinders ergibt sich aus dem fließenden Volumenstrom  $Q_{Zyl}$  und der mit dem Druck beaufschlagten Kolbenfläche  $A_{Zyl}$  [WILL15]. Diese Gleichung gilt nur für den idealisierten Fall ohne Druckaufbau und kann als Näherung des statischen Zusammenhangs verwendet werden.

$$v_{Zyl} = \frac{Q_{Zyl}}{A_{Zyl}} \quad (2.1)$$

Die Kolbenfläche in Gl. (2.1) ist nicht veränderlich, daher muss zur Änderung der Geschwindigkeit des Arbeitszylinders der fließende Volumenstrom  $Q_{Zyl}$  angepasst werden. Der Volumenstrom in hydraulischen Systemen lässt sich prinzipiell durch den Einsatz von Verstellpumpen mit variablem Fördervolumenstrom oder durch Stromventile anpassen. Bei dem Einsatz von Verstellpumpen wäre jedoch aufgrund des begrenzten Arbeitsbereiches für jeden einzelnen Verbraucher eine eigene Pumpe notwendig. Aus konstruktiver sowie wirtschaftlicher Sicht ist diese Methode für mobile Arbeitsmaschinen nicht sinnvoll [KUNZ02]. Daher wird die Versorgung des Systems meist von einer zentralen Pumpe übernommen, die direkt von einem Dieselmotor angetrieben wird und die einzelnen Verbrauchervolumenströme über Stromventile aufteilt [KUNZ02]. Die Ströme in den Ventilen werden mittels Blenden eingestellt. Der eingestellte Volumenstrom  $Q_{Zyl}$  ergibt sich aus der Blendengleichung Gl. (2.2).

$$Q_{Zyl} = k_{Bl} \cdot A_{Bl} \cdot \sqrt{\Delta p} \quad \text{mit} \quad k_{Bl} = \sqrt{\frac{2}{\rho \cdot \zeta}} \quad (2.2)$$

Es ist zu erkennen, dass der Volumenstrom  $Q_{Zyl}$  von dem Öffnungsquerschnitt der Blende  $A_{Bl}$ , dem Blendenkoeffizient  $k_{Bl}$  und der Druckdifferenz  $\Delta p$  abhängt. Man geht davon aus, dass der Blendenkoeffizient bei den Arbeitsdrücken und Temperaturen näherungsweise konstant ist und die Druckdifferenz lautunabhängig über die Blende konstant gehalten wird. Hierzu kommen bei hydraulischen Maschinen meist Druckwagen zum Einsatz [KUNZ02]. Ist der Druck über die Blende konstant so hängt der Volumenstrom lediglich von dem Öffnungsquerschnitt  $A_{Bl}$  der Blende ab.

#### 2.2.2 Proportionalventile

Wie gezeigt wird der Volumenstrom durch einen Öffnungsquerschnitt begrenzt. Die Regelung mit variablen Querschnitten kommt bei der Druck- oder Volumenstromregelung zum Einsatz. Soll dieser Volumenstrom variabel eingestellt werden kommen hierzu Proportionalventile zum Einsatz.



Diese können Teilvolumenströme steuern oder regeln. Sie gehören zu den Wegeventilen und können beliebige Zwischenpositionen annehmen. [WATT17]

Dadurch ist es beispielsweise am Bagger möglich den Auslegerzylinder einzufahren, auszufahren oder zu halten, indem das Proportionalventil über eine Stellgröße [ $s \in \mathbb{R} \mid -100 \% \leq s \leq 100 \%$ ] den Volumenstrom zu dem Zylinder einstellt [KUNZ02]. Die Betätigung des Ventils kann dabei mechanisch oder elektromechanisch erfolgen [WATT17].

## 2.3 Hydraulische Steueranordnungen

Aufgrund der Varianz von mobilen Arbeitsmaschinen gibt es auch eine große Anzahl hydraulischer Systemlösungen [KUNZ02]. Nachfolgend werden die Systeme mit einer hohen Verbreitung bei Baggern vorgestellt. Die Systemlösungen lassen sich nach Art der Speisung und Steuerung einteilen. Die Speisung wird in aufgeprägtem Volumenstrom (in der Regel Open-Center-Systemen) und aufgeprägtem Druck (meistens Closed-Center-Systemen) unterteilt. Die vorgestellten Systemlösungen gibt es sowohl als Konstantdruck- als auch Konstantstromsysteme. [MURR12]

### 2.3.1 Load-Sensing Systeme

Das hydraulische System von einem Bagger besitzt mehrere Verbraucher und eine Pumpe. Damit eine schnelle Ausführung der Arbeitsbewegungen gewährleistet ist, müssen die Volumenströme je nach Bedarf aufgeteilt werden [KUNZ02]. Weiterhin sollen die Druckverluste trotz Widerstandssteuerung mit Stetigsteuerventilen in Grenzen gehalten werden [WILL15]. Um die Verteilung der Volumenströme und die Reduzierung der Druckverluste zu erreichen, hat sich das hydraulische LS bei der Versorgung mehrerer ventilgesteuerter Verbraucher mit nur einer Pumpe durchgesetzt [WEIS95]. Grundprinzip des LS ist, dass die Druckquelle den geforderten Volumenstrom der Verbraucher, bei einem Mindestdruckniveau des aktuell lasthöchsten Verbrauchers, zur Verfügung stellt [WILL15]. Die Abb. 2.4 zeigt qualitativ den Aufbau eines rein hydraulischen LS-Systems.

Die gezeigten Verbraucher entsprechen zulaufstromgeregelten Antrieben. Im unteren Teil des Schaltplans ist eine Pumpe mit Stelleinrichtung zu sehen. Es ist zu erkennen, dass nicht nur der Quellendruck  $p_{pmp}$  zur Steuerung der Pumpe, sondern die Differenz aus dem Quellendruck  $p_{pmp}$  und dem maximalen Lastdruck  $p_{LS}$  verwendet wird. Der Lastdruck wird aus dem Belastungszustand der aktiven Antriebe gewonnen. Hierfür wird wie in der Abb. 2.4 dargestellt, zunächst die Druckdifferenz mit Hilfe von Druckdifferenzventilen gemessen. Anschließend wird der höchste Druck  $p_{LS}$  über eine Verschaltung von Wechselventilen ermittelt und der LS-Signalleitung zugeführt. Dieser wird auf die Federseite des Druckfühlers gelegt und sorgt dafür, dass der Druck der Pumpe immer Werte annimmt, die über dem erforderlichen Druck  $\Delta p_{erf}$  über Lastdruck liegen

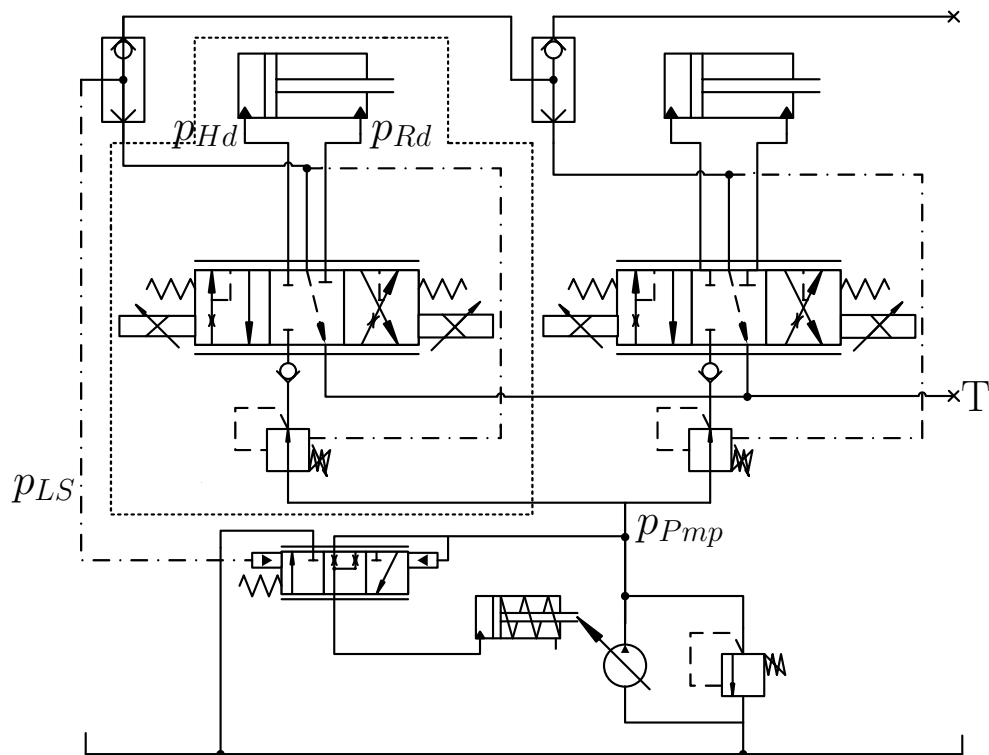


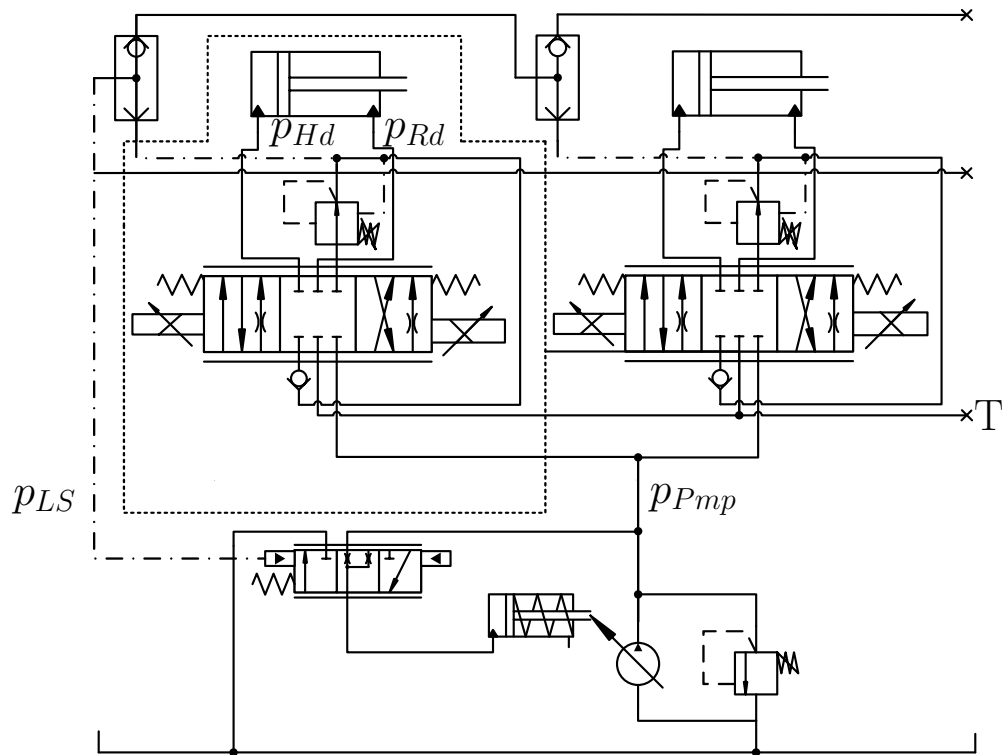
Abbildung 2.4: LS System

[WILL15]. Hauptnachteil des LS-System ist, dass der Sollwert der Druckquelle auf den höchsten zu erwartenden Lastdruck, zuzüglich einer für die Steuerventile notwendigen Druckdifferenz, eingestellt sein muss. Gegen kleine Lastdrücke entstehen in den Steuerspalten der Ventile große Druckabfälle, die bei Leistungsantrieben (die Volumenströme sind zusätzlich groß) hohe Drosselverluste hervorrufen [WATT17].

### 2.3.2 Lastdruckunabhängige Durchflussverteilung

Stellen die Verbraucher des Hydrauliksystems Anforderungen an die Pumpe die das Leistungsvermögen überschreiten, so können verschiedene Strategien eingesetzt werden Energie aufzuteilen. Werden keine Maßnahmen ergriffen, teilt sich der Volumenstrom zugunsten der Verbraucher mit den geringsten Lastdrücken auf. Diese Art der Verteilung führt meist zu einer ungewollten Bewegung [WILL15]. Eine Möglichkeit die ungewollten Bewegungen zu kompensieren ist die LUDV. Bei der LUDV handelt es sich um eine Weiterentwicklung der LS-Systeme. Dieses System findet vor allem Einsatz in mobilen Baggern im europäischen Raum [KUNZ02]. Anders als bei herkömmlichen LS-Systemen mit nachgeschalteter Druckwaage wird wie in Abbildung Abb. 2.5 gezeigt, nicht der Druck vor der Messblende mit dem Druck dahinter verglichen, sondern der Druck hinter der Messblende mit einem Lastmeldekanal. Dies hat zur Folge, dass die Druckdifferenz über alle Steu-

erventile gleich groß ist und der Volumenstrom sich proportional zu den Öffnungsquerschnitten der Messblenden aufteilt.



### Abbildung 2.5: LUDV System

Bei der LUDV sind zwei Betriebsfälle zu unterscheiden. Kommt es zur Unterversorgung zeigen sich die wesentlichen Unterschiede zu den LS-Systemen. In diesem Fall ist die Volumenstromanforderung gering und dadurch ist der LS-Regler aktiv. Dieser bestimmt den Druckabfall über die Messdrosseln und über die Druckdifferenzventile. Während bei LS-Systemen der lasthöchste Verbraucher gedrosselt wird, kommt es bei LUDV-Systemen zu einer gleichmäßigen Unterversorgung aller Verbraucher. [FINZ11]

Ist der Volumenstrombedarf der Verbraucher hoch (Fall 2), so spricht der Leistungsregler an und an allen Antrieben stellt sich die Druckdifferenz  $\Delta p_{Dri}$  ein. Dadurch kommt es zu einer Absenkung des Quellendrucks  $p_{pmp}$  und an allen Verbrauchern wird der Volumenstrom annähernd gleich abgesenkt. [WILL15].

## 2.4 Einflussfaktoren bei der Regelung von hydraulischen Systemen

In der Vergangenheit wurden häufig nur lineare Methoden zur Regelung von hydraulischen Systemen eingesetzt. Diese Strategien können jedoch kein optimales Verhalten bieten [ADAM18]. Wie in [EDGE03] gezeigt, haben komplexe Strategien nur wenig Anwendung in kommerziellen Produkten gefunden. Die industrielle Praxis hat gezeigt, dass das Anpassen von zwei oder drei Regelparametern mit dem Trial-and-Error Prinzip bereits sehr zeitaufwändig ist und ein gutes praktisches und theoretisches Verständnis von dem Operator voraussetzt [KOMS13]. Daher sind weiterhin in vielen Anwendungen nur klassische lineare Methoden zu finden. Mit der Entwicklung von nichtlinearen Modellierungsmethoden sind neue und komplexere Regelungsstrategien, wie z. B. in [KLEI93] vorgestelltem adaptiven Fuzzy Regler, entstanden. Diese Methoden können die Reglerperformance bei nichtlinearen Systemen erhöhen [ZHU18]. Eine Übersicht häufig verwendeter linearer Regler ist in [MURR12] zu finden. Eine Übersicht der fortschrittlichen nichtlinearen Regler gibt [EDGE03].

Bei der Auswahl von Reglern werden bestimmte Anforderungen an die Entwicklung gestellt. Die Abb. 2.6 zeigt eine Übersicht über die Einflussfaktoren für elektrohydraulische Systeme. Die Anforderungen lassen sich in vier Kategorien unterteilen, welche das dynamische Verhalten beeinflussen und dadurch die Performance des geschlossenen Regelkreises bestimmen.

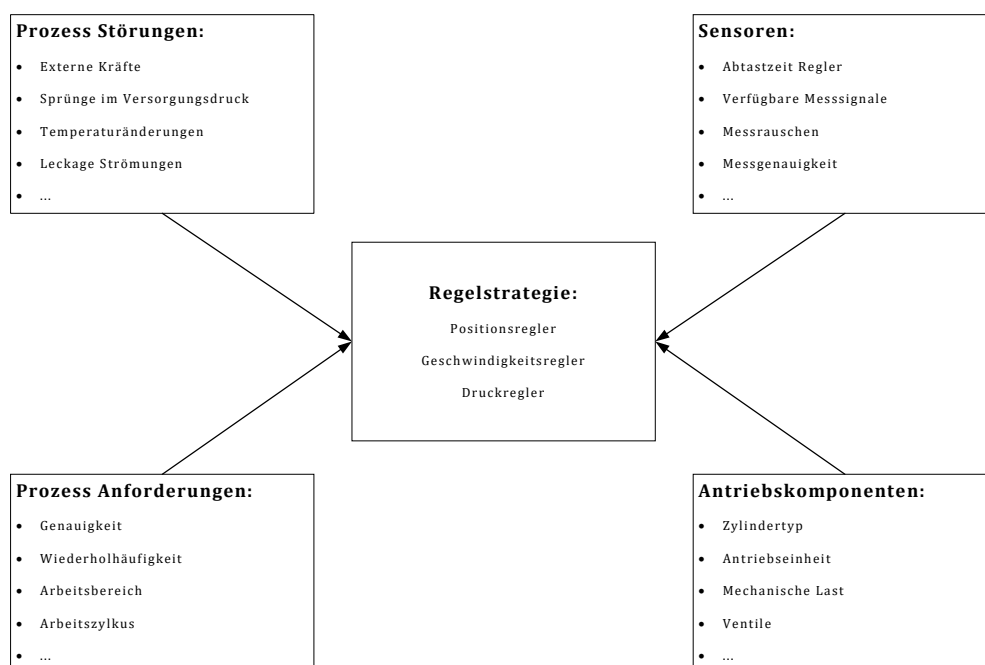


Abbildung 2.6: Übersicht der Einflussfaktoren bei der Entwicklung einer Regelstrategie für hydraulische Systeme

Das dynamische Verhalten wird durch die verbauten Antriebskomponenten vorgegeben und durch die Prozessstörungen beeinflusst. Darunter zählen externe Einflüsse, wie zum Beispiel einwirkende Kräfte oder auch interne Störungen wie Leckage Strömungen. Diese Komplexität macht es schwierig die Regelstrecke nachzubilden. Weiterhin muss die Sensorkonfiguration bei der Entwicklung beachtet werden. Jeder zusätzliche Sensor erhöht die Systemkosten. Das Problem bei der Auswahl der Sensoren ist, dass das Messrauschen und die Messungenauigkeiten eine Störung darstellen. Durch diese Störungen wird die Komplexität der Entwicklung von Regelstrategien erhöht. [KOMS13]

## 2.5 Versuchsträger

Im folgenden Kapitel wird der Versuchsträger für die Überprüfung der Machbarkeit von datenbasierten Methoden näher vorgestellt. Bei dem Referenzobjekt handelt sich um den Mobilbagger *Hydradig* der Marke JCB, mit einem Betriebsgewicht von 12 t und einem Radstand von 2650 mm. Die Abbildung Abb. 2.7 zeigt den Mobilbagger.



Abbildung 2.7: Versuchsträger JCB Hydradig

Es ist zu erkennen, dass der Bagger im Vergleich zu Stand- oder Raupenbaggern ein konventionelles Fahrwerk mit Rädern besitzt, welche zur Fortbewegung von Hydromotoren angetrieben werden. Dadurch kann der Bagger eine maximale Geschwindigkeit von 40 km/h erreichen. Somit ist die Maschine auch in der Lage am Straßenverkehr teilzunehmen und Kurzstrecken, ohne

Einsatz einer zusätzlichen Transportmaschine zu überwinden. Die Hydromotoren und die Arbeitseinheiten werden durch einen 110 kW starken Dieselmotor versorgt. Bei den Hydraulikzylindern für den Löffel, Arm, Verstellausleger und Ausleger handelt es sich um doppelwirkende asymmetrische Hydraulikzylinder mit gehärteten und verchromten Kolbenstangen. Diese werden von einer Axialkolben-Verstellpumpe mit einem maximalen Nutzdruck von 280 bar und einem maximalen Fördervolumenstrom von 41,8 g/min versorgt. Das hydraulische System ist nach dem im Abschnitt 2.3.2 vorgestellten LUDV-System aufgebaut. [BAMF19]

Da es sich bei dem verwendeten Bagger um einen Versuchsträger handelt, ist der Bagger mit einer Reihe von Sensoren ausgestattet. Für die Messung der Position der einzelnen Achszylinder sind Seilzugsensoren verbaut. Diese Sensoren können auch eingesetzt werden um die Geschwindigkeiten der einzelnen Zylinder zu bestimmen. Neben den Positionssensoren ist jeder Zylinder zusätzlich mit Sensoren an der Pleuel- und Kopfseite ausgestattet, um den dynamische Druckaufbau in den Zylindern aufzuzeichnen. Für die Messung der Systemdrücke sind Sensoren für den Lastdruck  $p_{LS}$  und Pumpendruck  $p_{Pmp}$  vorhanden.

### 2.5.1 Steuerung mit Hilfe von Joysticks

Der Bagger wird mit unterschiedlichen Bedienelementen gesteuert. Die Bedienung von aktuellen Baggern wird mit Hilfe von Pedalerie, Lenkrad, Joysticks und Bedienkonsolen durchgeführt [LORE17]. Die Steuerung der Hauptzylinder über Joysticks basiert heute noch auf einer Bedienlogik, welche der Steuerung der einzelnen Hydraulikkanäle zugrunde liegt [KUNZ02]. Die Abb. 2.8 zeigt die Belegung der Joysticks (sog. Europa-Steuerung), welche häufig bei Baggern zu finden ist [KUNZ02].



Abbildung 2.8: Belegung der Joysticks eines Baggers

Den Hauptarbeitszylindern wird hier eine Raumrichtung auf den Joysticks zugewiesen. Mit dem linken Joystick werden dabei die Drehung des Oberwagens und die Bewegung des Stielzylinders gesteuert. Der rechte Joystick steuert das Heben und das Senken von dem Ausleger und dem Löff-

felzylinder. Soll nun beispielsweise eine Bewegung der Schaufelspitze (TCP) durchgeführt werden, so muss die Position durch drei Zylinder gleichzeitig eingestellt werden. Dieses Beispiel verdeutlicht bereits die Komplexität der Bedienung von Baggern. Neben den Hauptfunktionen werden die Bedienelemente auf den Joysticks mit weiteren Zusatzfunktionen und Schnellzugriff-Funktionen belegt [LORE17].

Im Gegensatz zu rein hydraulischen Baggern wird in elektrohydraulischen Systemen das Joystick-signal zunächst in einer Betriebssteuerung digital verarbeitet. Der Wert des Joysticksignals wird in Promille (‰) angegeben. Dieses Joysticksignal wird von der Betriebssteuerung in den notwendigen Stellstrom des Ventils gewandelt. Außerdem wird von der Betriebssteuerung auch die Ansteuerung der hydraulischen Pumpe übernommen.

### 2.5.2 Automatisierung der Bewegung

Das Ausheben von einfachen Erdarbeiten und das Planieren von Materialien sind Aktivitäten, welche sich durch eine Sequenz von sich wiederholenden Vorgängen darstellen lassen. Das bietet eine gute Voraussetzung, durch den Ansatz von Konzepten der Robotik, die Bewegung zu automatisieren. Dadurch kann die Maschinennutzung und der Durchsatz gesteigert werden. Weiterhin bietet die Automatisierung den Vorteil, dass geringere Anforderungen an den Bediener gestellt werden können und gleichzeitig die Arbeitsauslastung des Bedieners verringert werden kann. [BRAD98]

Die Automatisierung von Arbeitsmaschinen ist ein aktiver Forschungs- und Entwicklungsbereich der letzten drei Jahrzehnte geworden [HEMA09]. Wie in [MAED13] festgestellt, wurde trotz Forschungen auf dem Gebiet noch keine vollständige Automatisierung eines Baggers präsentiert. Daraus lässt sich schließen, dass die Automatisierung keine einfache Aufgabe darstellt. Die Schwierigkeit liegt unter anderem daran, dass es keine genauen Modelle zur Beschreibung des Prozesses gibt [DADH15]. Die Herausforderung macht es schwierig den Prozess vollständig zu automatisieren. Daher zielen die Forschungsschwerpunkte auf kleinere Schritte hin zu der vollständigen Automatisierung ab. Wie in [ROBE02] dargestellt, führt der Weg zur vollständigen Automatisierung zunächst über die Entwicklung von Assistentenfunktionen, bei denen der Bediener nur die Aufgabe der Überwachung und Freigabe des Prozesses hat.

Um ein Forschungsprojekt seitens Bosch zu ermöglichen, wurde der im Kapitel 2.5 vorgestellte Mobilbagger der Marke JCB zu einem Versuchsträger umgebaut. Hierfür wurde der Bagger mit einer MicroAutoBox von DSpace ausgestattet. Es handelt es sich hier um ein robustes Prototyping-System für Echtzeitsysteme mit einer umfassenden I/O. Durch den Einsatz dieses Systems ist es möglich Rapid-Control-Prototyping (RCP) zu betreiben. Für die Entwicklung der Regelstrategien kommt Matlab Simulink zum Einsatz. Dadurch können zunächst die Regelstrategien an einem Simulationsmodell getestet werden und anschließend direkt auf dem Versuchsträger validiert werden.

### 2.5.3 Software Struktur: Assistenzfunktionen

Für die Entwicklung teilautonomer Bagger wurde die Struktur in Abb. 2.9 entwickelt. Das Blockdiagramm zeigt die einzelnen Elemente welche für die Regelung des Baggers notwendig sind. Im ersten Schritt wird von dem Pfadplaner eine Solltrajektorie in realen Weltkoordinaten für den TCP der Baggerschaufel berechnet. Dies ist möglich, da die häufigsten Aufgaben eines Baggers (wie z. B. das Ausheben eines Loches) als eine Abfolge von Solltrajektorien angesehen werden können.




Abbildung 2.9: Überlagerte Software Struktur für das autonome Baggern

Wie in der Abb. 2.9 zu sehen, wird aus der Regeldifferenz zwischen diesen Sollkoordinaten  $x_{e,des}$  und der gemessenen Koordinaten des Endeffektors  $x_e$  mit Hilfe des Posen-Reglers von den Koordinaten auf die Sollgeschwindigkeiten  $\dot{x}_{e,des}$  abgebildet. Anschließend ist es notwendig auf die passenden Zylinder- und Gelenkgeschwindigkeiten zu schließen. Hierfür muss das aus der Robotik bekannte Inverse-Kinematik-Problem gelöst werden. Die Lösung des Problems ist eine komplexe Aufgabe, da die zu lösenden Gleichungen nichtlinear sind und außerdem auch mehrere Lösungen existieren können [SPON08]. Das Problem wurde durch Differentialgleichungen und die Jacobimatrix des Baggers vereinfacht und durch Lösung eines Optimierungsproblems gelöst. Näheres hierzu kann in [BEND16] nachgelesen werden. Dadurch ist es möglich auf die Sollzylinder- und Gelenkgeschwindigkeiten  $\dot{s}_{des}$  zu schließen.

Mit diesen Sollwerten kann mit Hilfe eines Geschwindigkeitsreglers die Geschwindigkeit der Achszylinder geregelt werden. Der Geschwindigkeitsregler stellt den Fokus dieser Arbeit dar und wird im nachfolgenden Abschnitt näher beschrieben. Wie in der Abb. 2.9 zu sehen, bestimmt dieser die Eingangsgröße  $Jystk$  für die Regelstrecke. Die Eingangsgröße  $Jystk$  der Regelstrecke ist an dem Versuchsträger das Joysticksignal, da nicht in die eingebaute Betriebssteuerung eingegriffen werden soll. Die Stellgröße wird von der Betriebssteuerung verarbeitet. Diese gibt unter anderem die Signale für die Ventilsteuerung und Pumpenreglung vor. Die Ansteuerung der Ventile führt zu einer Änderung der Blendenöffnungsfläche, wodurch es zu einer Freigabe des Volumenstroms kommt.

Dieser Volumenstrom wirkt auf die Hydraulikzylinder und setzt diese in Bewegung. Durch die Vorwärtskinematik kommt es zur Bewegung des TCP in real Koordinaten  $x_e$ . Durch Einsatz von Sensoren und modellbasierten Filtern kann auf die notwendigen rückgeführten Signale geschlossen werden.



### 2.5.4 Regelung der Zylindergeschwindigkeit

Wie in dem vorherigen Absatz bereits erwähnt wurde, liegt der Fokus der Arbeit auf der Entwicklung des Geschwindigkeitsreglers für die Achszylinder. Die Schwierigkeit bei der Entwicklung liegt darin, dass das Systemverhalten des Baggers sehr komplex ist. Insbesondere das Verhalten der hydraulischen Komponenten ist stark nichtlinear [CHAC14]. Außerdem ist das System schwingungsfähig, wodurch eine aggressive Anregung vermieden werden sollte [JELA12]. In Voruntersuchungen hat sich gezeigt, dass ein klassischer PI-Regler für die gewünschten Anforderungen des Systemverhaltens nicht garantieren kann.

Daher wird als nichtlineares Regelungskonzept der PI-Regelung mit Vorsteuerung ergänzt. Die Basis hierfür bildet das in der Literatur als Exakte Feedforward Linearisierung bekannte Verfahren [SPON08]. Bei diesem Ansatz wird eine Vorsteuerung mit einem PI- oder PD-Regler kombiniert. Dabei soll die Vorsteuerung durch Einsetzen der Sollwerte die dafür notwendige Stellgröße bestimmen und der PI-Regler nur die Modellungenauigkeiten und externen Störungen kompensieren [GATT11].

Dieser Ansatz wurde bereits in einem Forschungsprojekt validiert. Die Abb. 2.10 zeigt den dafür verwendeten Regler. Die Strecke lässt sich vereinfacht in die Ventildynamik, Hydraulikdynamik und Zylinderdynamik unterteilen.

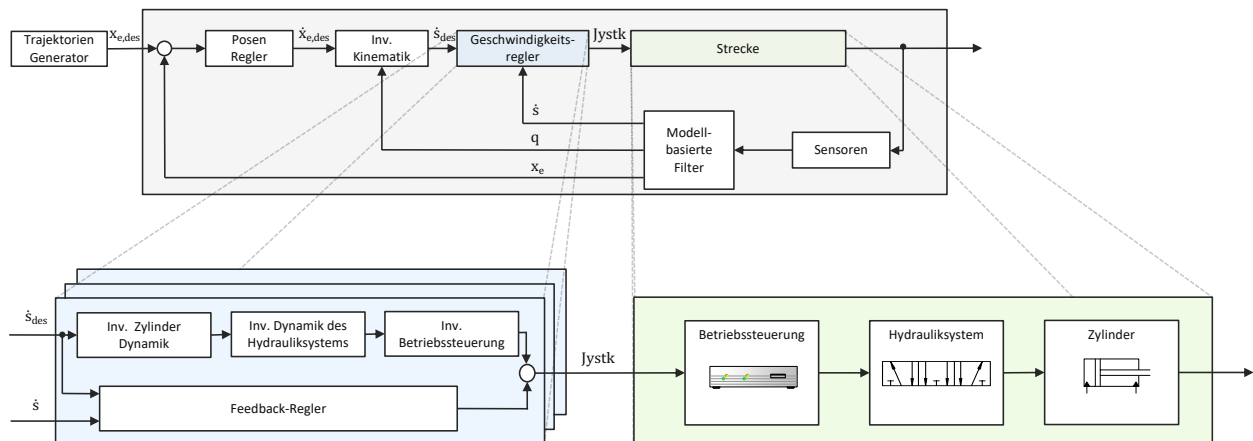


Abbildung 2.10: Geschwindigkeitsregler mit physikalischem Modell

Im Rahmen des Forschungsprojektes wurde das inverse Verhalten des Streckenverhaltens modelliert. Hierfür wurde Simulationsmodell des Baggers erstellt und das inverse Verhalten daran abgeleitet. Die Vorsteuerung konnte wie in der Abb. 2.10 zu sehen in die inverse Betriebssteuerung, inverse Zylinderdynamik und die inverse Dynamik des hydraulischen Systems zerlegt werden. Bei der Modellierung wurde die Annahme getroffen, dass ein statischer Zusammenhang vorliegt, da für die dynamischen Effekte zusätzliche Sensoren notwendig sind.

## 2.6 Signalverarbeitung

### 2.6.1 Filter

Der Filter hat die Aufgabe bei der Analyse oder der Übertragung von Signalen bestimmte Frequenzanteile auszusondern oder hervorzuheben [BEUC19]. Der Filter kann unerwünschte Signale unterdrücken und die Signalleistung in einem bestimmten Frequenzbereich steigern oder senken. Aufgrund der vielfältigen Anwendungen existieren viele analoge und digitale Filter. In der Regel können Filter durch lineare frequenzabhängige Systeme angenähert werden, die einen Sperrbereich, Durchlassbereich und dazwischenliegenden Übergangsbereich besitzen [MEYE14]. Je nach Frequenzbereich in dem das Eingangssignal des Filters mit unveränderter Amplitude durchläuft lassen sich Filter in Tiefpässe, Hochpässe und Bandpässe einteilen. Die Abb. 2.11 zeigt die idealisierte Darstellung der Filtertypen im Frequenzbereich.




Abbildung 2.11: Frequenzgang der unterschiedlichen Filtertypen

Wie in der Abbildung zu sehen ist, lässt der Tiefpassfilter nur die Amplituden aller Spektralanteile des Signals für einen Frequenzbereich  $[-\omega_g, \omega_g]$  unverändert. Der Bandpass lässt nur Frequenzanteile im Bereich  $[\omega_u, \omega_o]$  passieren, wo hingegen der Hochpass nur hochfrequente Anteile oberhalb der Grenzfrequenz  $\omega_g$  durchlässt.

### System erster Ordnung (PT1-System)

Der in der Abb. 2.11b gezeigte Tiefpassfilter stellt die ideale Form dar. Der ideale Amplitudengang ist jedoch nicht realisierbar [MEYE14]. Eine einfache Form eines Tiefpassfilters stellt ein System erster Ordnung dar. Das System lässt sich durch die Übertragungsfunktion (Gl. (2.3)) beschreiben.

$$G(s) = \frac{1}{T_F s + 1} \quad (2.3)$$

In der Gleichung stellt  $T_F$  die Zeitkonstante des Filters dar. Die Zeitkonstante bestimmt die Grenzfrequenz des Tiefpassfilters. Als Grenzfrequenz wird die Frequenz bezeichnet, bei der sich der Eingang des Filters gegenüber dem Ausgang um 3 dB abgesenkt hat [BEUC19]. Zur Darstellung des Übertragungsverhaltens des Filters dient das Bode-Diagramm. In dem Bode-Diagramm wird der Amplitudengang und der Phasengang einer komplexwertigen Funktion gezeigt. Die Abb. 2.12 zeigt die Verläufe für die in der Gl. (2.3) dargestellten Übertragungsfunktion.




Abbildung 2.12: Bode-Diagramm für einen Filter erster Ordnung

Die Abb. 2.12 stellt das Verhalten des Systems in Abhängigkeit von der Frequenz dar. Die Darstellung zeigt den Verlauf für eine Zeitkonstante von  $T_F = 0,1$ . Es ist zu erkennen, dass die Grenzfrequenz bei 10 Hz liegt. In dem Amplitudengang ist zu sehen, dass der Filter bei einer Verdopplung der Frequenz die Amplitude des Signals halbiert. Dies zeigt sich durch eine Absenkung des Amplitudengangs um 20 dB pro Dekade. Je höher der Grad, desto steiler der Übergangsbereich und desto größer auch der Realisierungsaufwand [MEYE14]. Das Bode-Diagramm in Abb. 2.12 zeigt neben dem Amplitudengang auch den Phasenverlauf. Dieser Verlauf stellt die frequenzabhängige Phasenverschiebung zwischen Eingangs- und Ausgangssignal dar. Wie in der Abb. 2.12 zu sehen

verläuft die Phase von 0 deg bis  $-90$  deg. Bei der Grenzfrequenz von 10 Hz beträgt die Phasenverschiebung bei einem System erster Ordnung  $-45$  deg. Mit Zunahme der Ordnung der Übertragungsfunktion steigt die Phasenverschiebung des Ausgangs. Der Filter erster Ordnung hat daher den Vorteil einfach implementiert werden zu können.

### 3 Grundlagen der datenbasierten Modellierung

Dieses Kapitel führt in die Grundlagen der datenbasierten Modellierung ein. Unter der Modellierung versteht man die Beschreibung des Verhaltens eines Systems, anhand von mathematischen Konzepten. Hierfür kommt das Prinzip von Ursache und Wirkung zum Einsatz [BOHN16].

Diese daraus resultierenden Modelle eines Systems und seiner Umgebung können für die Planung und Regelung von dynamischen Systemen eingesetzt werden [NGUY11]. Dabei ermöglicht erst ein hinreichend genaues Modell den Einsatz in einer modellbasierten Regelung [DEFL11]. Reale Systeme sind häufig komplex und haben eine ständige Wechselwirkung zu ihrer Umgebung, eine vollständige mathematische Beschreibung ist daher nahezu unmöglich [WANG11]. Somit muss die Komplexität reduziert werden, um das Verhalten für die anwendungsspezifische Genauigkeit zu beschreiben. Hierfür werden bei der Modellbildung Annahmen, Systemgrenzen und Vereinfachungen festgelegt um das wesentliche Systemverhalten mit überschaubarem Aufwand darstellen zu können [ZHU18].

Die Modellierungsansätze lassen sich wie in Abb. 3.1 dargestellt, generell in theoretische und datenbasierte Methoden klassifizieren. Die theoretischen Methoden basieren auf der mathematischen Beschreibung (unter Anwendung von physikalischen Gleichungen) welche die Eingänge, Zustände, Parameter und Ausgänge miteinander verknüpfen [ISER10].

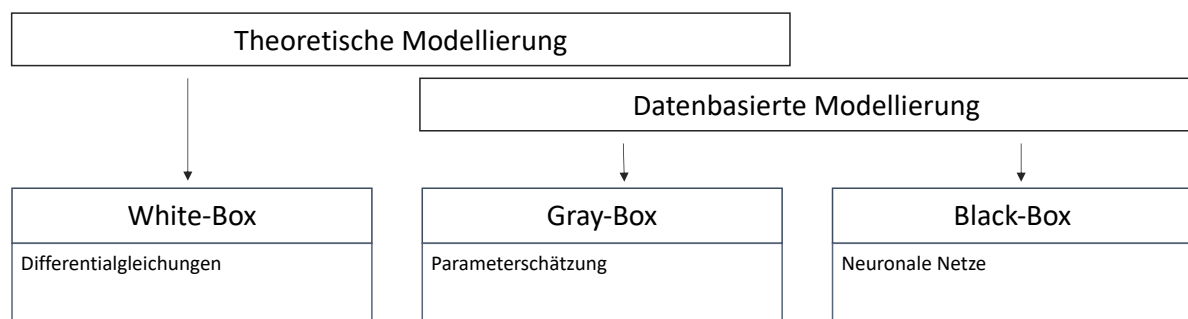


Abbildung 3.1: Ansätze zur Modellierung von dynamischen Systemen

Rein theoretische Ansätze werden als White-Box Modelle bezeichnet. Bei der Beschreibung des Verhaltens kommen dabei Bilanzgleichungen, physikalische oder chemische Zustandsgleichungen,

phänomenologische Gleichungen und Kopplungsgleichungen zum Einsatz [ISER05]. Eine Kombination dieser Gleichungen führt zu einem Differential-algebraischen Gleichungssystem, welches das Verhalten des Systems beschreibt. Modelle welche nur auf Daten basieren werden als Black-Box Ansätze bezeichnet. Bei diesem Ansatz wird das Systemverhalten nachgebildet ohne die Struktur des Systems zu kennen [BOHN16]. Eine Mischform der datenbasierten und theoretischen Ansätze ist die Gray-Box Modellierung, welche auch als hybride Modellierung bekannt ist. Bei den hybriden Modellen wird das Systemverhalten durch physikalische Grundgesetze beschrieben und die Parameter werden durch die Daten approximiert. Bei der reinen theoretischen Beschreibung kommt es laut [ISER10] zu folgenden Schwierigkeiten:

- Die theoretische Beschreibung kann selbst bei einfachen Systemen komplex sein
- Modellparameter sind meist nicht hinreichend genau
- Im System sind nicht alle auftretenden Vorgänge bekannt
- Die auftretenden Vorgänge lassen sich nicht mathematisch beschreiben
- Manche Systeme benötigen zu viel Zeit für die theoretische Beschreibung

Wegen diesen Schwierigkeiten und der teilweise kürzeren Modellierungszeit haben die datenbasierten Methoden an Bedeutung gewonnen [SJÖB95]. Im Gegensatz zur theoretischen Vorgehensweise werden bei der datenbasierten Modellbildung die mathematischen Modelle anhand von Experimenten erstellt. Die Analyse dieser Experimente erlaubt mathematische Modelle zu erzeugen, welche das Streckenverhalten beschreiben. Für diesen Ansatz ist es jedoch notwendig Daten an dem realen System aufzunehmen [BOHN16]. Bei diesen Experimenten werden das zeitliche Verhalten der Eingangs- und Ausgangsgrößen sowie die Zustände aufgezeichnet. Dabei können die Eingangssignale entweder die Anregungen während des regulären Betriebs sein oder künstlich erzeugte Eingangssignale [WANG11].

### 3.1 Problemformulierung

Diese Arbeit beschränkt sich auf die datenbasierte Black-Box-Modellierung. Für den Versuchsträger liegt zwar ein Simulationsmodell für die Beschreibung der Streckenverhaltens vor jedoch wird in der Arbeit davon ausgegangen, dass die Parameter des Modells und die genaue Struktur unbekannt sind. Die Arbeit zielt darauf ab zu untersuchen ob es möglich ist das Verhalten auch ohne Vorwissen nachbilden zu können, um dadurch eine einfache Übertragbarkeit auf andere Bagger zu garantieren.

Allgemein kann das Problem nach Gl. (3.1) definiert werden. Die Gleichung zeigt die allgemeine Formulierung eines dynamischen Systems, welches in dem Zustand  $\underline{x}_k$  einen Eingang  $\underline{u}_k$  erfährt und in den nächsten Zustand  $\underline{x}_{k+1}$  übergeht, wobei lediglich der Ausgang  $\underline{y}_k$  beobachtet werden

kann und eine Funktion des aktuellen Zustands und Eingangs ist. Da die Modellierung und Aufnahme der Messwerte digital erfolgt, wird die Gleichung in zeitdiskreter Form dargestellt. Dabei gilt der Zusammenhang  $\underline{\mathbf{u}}_k = \underline{\mathbf{u}}(kT_s + t_0)$ , wobei die Daten mit der Abtastrate  $T_s$  abgetastet werden.

$$\begin{aligned}\hat{\underline{\mathbf{x}}}_{k+1} &= f(\underline{\mathbf{x}}_k, \underline{\mathbf{u}}_k) \\ \hat{\underline{\mathbf{y}}}_k &= h(\underline{\mathbf{x}}_k, \underline{\mathbf{u}}_k)\end{aligned}\tag{3.1}$$

Die Funktionen  $f$  und  $h$  in Gl. (3.1) repräsentieren die Zustandsänderung und Ausgangsfunktion [NGUY11]. Das Modell für die Zustandsänderung  $f$  schätzt den zukünftigen Zustand  $\underline{\mathbf{x}}_{k+1}$ . Ziel der Modellierung ist es, den funktionalen Zusammenhang möglichst genau abzubilden [SJÖB95]. Vereinfacht lässt sich das Problem daher nach Gl. (3.2) darstellen. In der Anwendung können zur Prädikation verschiedene Regressoren verwendet werden. Die Gleichung wird in der allgemeinen Form (Gl. (3.2)) dargestellt. Dabei wird  $\underline{\phi}_k$  als Regressor bezeichnet.

$$\hat{\underline{\mathbf{y}}}_k = g(\underline{\phi}_k, \underline{\mathbf{w}})\tag{3.2}$$

Um die Funktion  $g(\cdot)$  darzustellen, muss die Funktion durch einen endlichdimensionalen Parametervektor  $\underline{\mathbf{w}}$  parametrisiert werden [LJUN99]. Die Einträge des Vektors werden auch als Gewichte bezeichnet. Die Funktion  $g(\cdot)$  in der Struktur 3.2 wird als Funktionsapproximator bezeichnet. Für die Modellierung des Systemverhaltens liegen bei der datenbasierten Modellierung die Ausgangsdaten  $\underline{\mathbf{y}} \in \mathbb{R}^{N_y}$  und  $\underline{\mathbf{u}} \in \mathbb{R}^{N_u}$ , sowie optional weitere Zustände  $\underline{\mathbf{x}} \in \mathbb{R}^{N_u}$ , vor.

Der Parametervektor wird durch Lösen des Optimierungsproblems 3.3 bestimmt. Die verwendete Norm kann je nach Aufgabenstellung und Optimierungsverfahren variieren. Die Optimierung der Parameter eines Funktionsapproximators wird in der Literatur häufig als Training bezeichnet. Der für das Training verfügbare Datensatz  $\underline{\phi}$  wird entsprechend Trainingsdatensatz genannt. [DEFL11]

$$\underline{\mathbf{w}}^* = \arg \min_{\underline{\mathbf{w}}} \left( \sum_{k=1}^K \|y_k - g(\phi_k, \underline{\mathbf{w}})\| \right)\tag{3.3}$$

### 3.1.1 Übersicht der Modellierungsansätze

Die in dem vorherigen Kapitel beschriebene Problemformulierung lässt sich auf unterschiedliche Modelle anwenden. Die Ansätze werden nach ihrem späteren Einsatzgebiet ausgewählt [NGUY11]. Die Abbildung Abb. 3.2 zeigt unterschiedliche Ansätze. In der Abb. 3.2 stellen die weißen Knoten beobachtete, beziehungsweise gemessene Quantitäten dar und die grauen Knoten die geschätzten Größen.

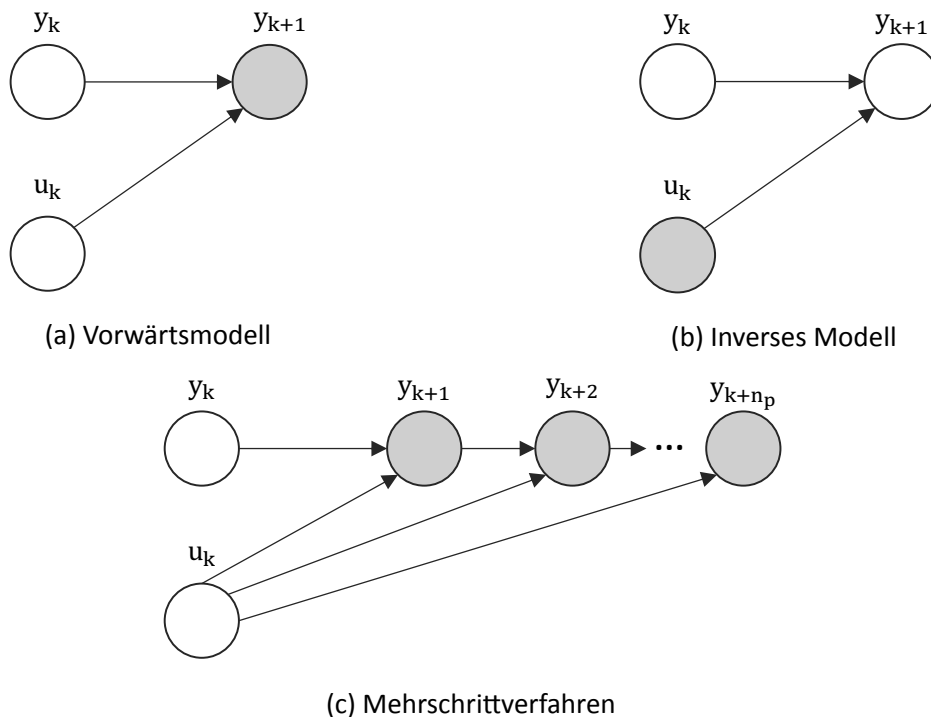


Abbildung 3.2: Modellstrukturen für die Beschreibung von dynamischen Systemen

Das Vorwärtsmodell (vgl. Abb. 3.2a) schätzt den zukünftigen Ausgang des Systems anhand des aktuellen Eingangs und Ausgangs. Dieser Modellansatz kommt beispielsweise in der Modellreferenz adaptiven Regelung [NARE12] oder der modellprädiktiven Regelung zum Einsatz [MACI02]. Bei der Modellreferenz adaptiven Regelung wird die Performance anhand des Vorwärtsmodells (Modellreferenz) der Fehler vorhergesagt und anschließend adaptiv angepasst. Werden mehrere Zeitschritte vorhergesagt (vgl. Abb. 3.2c), spricht man von Mehrschrittverfahren. Bei der Steuerung ist es sinnvoll Informationen über den Systemausgang für einen bestimmten Zeithorizont vorherzusagen, ohne die Messung des Systemausgangs zu besitzen [NGUY11]. Es hat sich gezeigt, dass diese Probleme aufgrund der fehlenden Messungen während der Vorhersage nicht einfach gelöst werden können. Werden die gleichen Methoden wie bei den Einzelschritt Vorwärtsmodellen gewählt, kommt es zu einer Aufsummierung der Fehler. Dabei werden die Fehler aus der Vergangenheit weiter in die Zukunft propagiert [AKAI98].

Bei dem in der Abb. 3.2b dargestellten inversen Modell wird von dem Zustand auf die dafür not-



wendige Aktion geschlossen. Dieser Ansatz kommt traditionell bei der Drehmoment-Regelung von Robotern zum Einsatz, indem das notwendige Drehmoment anhand der Solltrajektorie vorhergesagt wird [CRAI09]. Im Vergleich zu dem Vorwärtsmodell kann das inverse Modell eine nicht kausale Beziehung darstellen. Dies führt dazu, dass in manchen Fällen kein inverses Modell existiert oder zumindest nicht wohldefiniert ist. [NGUY11] Diese schlecht gestellten Lernprobleme treten bei nicht konvexen Datensätzen auf [JORD92].

## 3.2 Vorgehensweise der datenbasierten Modellierung

Die Vorgehensweise der datenbasierten Modellierung kann als sequentieller Vorgang mit spezifischen Iterationsschleifen betrachtet werden [BOHN16]. Der Prozess der Identifikation lässt sich allgemein durch vier Schritte beschreiben:

1. Versuchsplanung
2. Datenerfassung
3. Wahl des Identifikationsverfahrens
4. Validierung des ermittelten Modells

Im ersten Schritt wird ein Systemeingangssignal für eine gewisse Messzeit definiert. Dabei werden meist spezielle deterministische Testsignale (z. B. Sprunganregung) verwendet. Es ist darauf zu achten, dass das Testsignal  $u(t)$  genügend breitbandig ist, um das System hinreichend anzuregen. Im nächsten Schritt werden die Messungen durchgeführt und die Daten für das zuvor definierte Testsignal  $u(t)$  erfasst. Die Erfassung der Daten erfolgt aufgrund der digitalen Signalerfassung als Zeitreihe. Hierbei müssen die Messsignale möglichst stör- und rauschfrei aufgezeichnet werden.

Nachdem die Datenerfassung vollständig ist, wird das Identifikationsverfahren ausgewählt. Die Verfahren können abhängig von dem gewählten Testsignal und Problem gewählt werden. Mögliche datenbasierte Verfahren sind im folgenden Abschnitt näher beschrieben. Im letzten Schritt wird das erstellte Modell validiert. Dabei werden die geschätzten Werte aus dem Modell mit den realen Werten verglichen. Dieser Wert wird als Modellgüte bezeichnet. Die erforderliche Modellgüte ist abhängig von dem Anwendungsgebiet des erstellten Modells. [DEFL11]

### 3.2.1 Prozess der Identifikationsverfahrensauswahl

Wie bereits erwähnt umfasst die Vorgehensweise bei datenbasierten Methoden die Wahl des Identifikationsverfahrens. Dabei werden bei dynamischen Systemen die Modelle gewählt, welche möglichst gut das Systemverhalten beschreiben können [ZHU18]. Für die Bewertung des Modells können die in dem Kapitel 5.4.1 dargestellten Bewertungskriterien herangezogen werden. Erfüllt

das gewählte Modell das zuvor definierte Kriterium nicht, so muss die Identifikation weiter verbessert werden. Dieser Prozess lässt sich durch das Flussdiagramm in Abb. 3.3 darstellen.

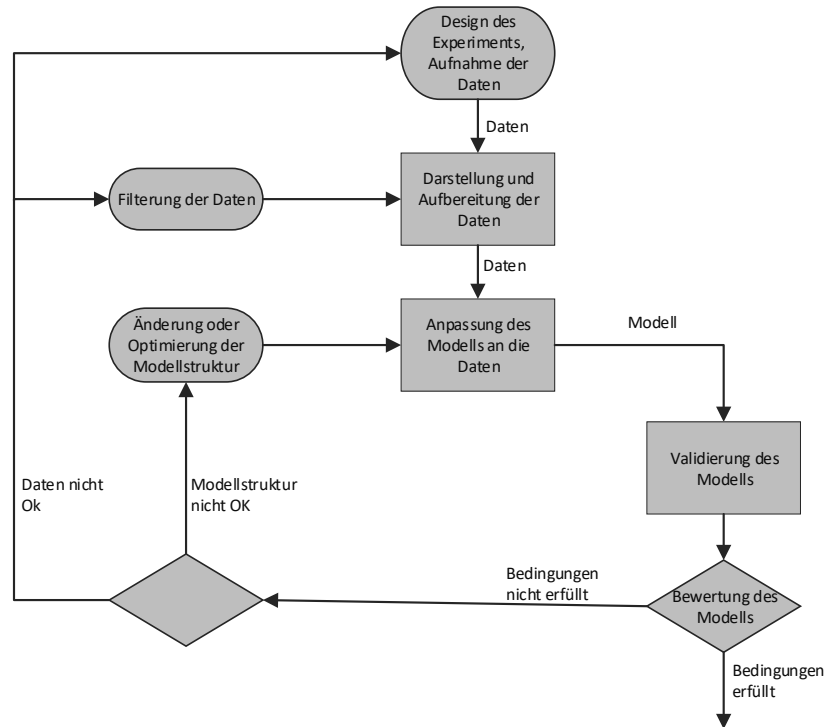


Abbildung 3.3: Iterativer Prozess zur Auswahl des besten Modells

Im ersten Schritt wird eine Versuchsreihe geplant und anschließend werden die Daten an dem realen Versuchsträger aufgenommen. Die aufgenommenen Daten müssen im nächsten Schritt dargestellt und für das Training des Modells vorbereitet werden. Mit Hilfe der Visualisierung der Daten kann eine Aussage über die notwendige Nachbearbeitung der Daten getroffen werden. Auf den aufbereiteten Daten kann ein Modell angepasst werden. Das angepasste Modell wird anschließend validiert. Es wird bewertet, wie gut das Modell das Verhalten auf einem neuen Datensatz (Validierungsdatsatz) performt, welcher nicht Bestandteil des Trainingsdatensatzes ist [LEVI18]. Dabei wird der simulierte Ausgang mit dem wahren Systemausgang mit einem Bewertungskriterium (siehe Kapitel 5.4.1) verglichen.

Erfüllt das Modell die Anforderungen, so kann es in der Anwendung noch weiter überprüft werden. Wird das Kriterium nicht erfüllt, so stehen zwei mögliche Schritte zur Auswahl. Zum einen kann das Problem auf die Daten und andererseits auf die Modellstruktur zurückgeführt werden. Liegt das Problem an den Daten, so kann zunächst eine wiederholte Filterung und Vorbereitung der Daten durchgeführt werden. Alternativ muss ein neuer Versuch geplant und durchgeführt werden. Liegt das Problem nicht an den Daten, so wird die verwendete Modellstruktur angepasst.

### 3.3 Neuronale Netze

Für die Identifikation des inversen Streckenverhaltens werden in dieser Arbeit Neuronale Netze untersucht. Die Anwendung Neuronaler Netze findet heutzutage immer mehr Anwendungsbereiche da die Rechenleistung zunimmt [ERTE16]. Sie besitzen das Potential auch komplexe Zusammenhänge approximieren zu können und stellen daher eine gute Möglichkeit für die Beschreibung von hydraulischen Systemen dar [JELA12].

Die künstlichen Neuronalen Netze orientieren sich an den biologischen Prozessen, nämlich an den basalen Operationen des Gehirns [KLÜV12]. Die Netzwerke bestehen aus einzelnen, parallel arbeitenden Neuronen. Neuronale Netze eignen sich besonders zur empirischen Modellierung. Durch ihren Aufbau können lineare und nichtlineare Funktionen approximiert werden [DEFL11].

#### 3.3.1 Aufbau von Multi-Layer-Perceptrons

Die künstlichen Neuronen werden als Schwellwertelement modelliert. Der Output  $o$  wird durch die Eingangsdaten  $\underline{x}$  abgebildet. Der Ausgang wird durch die folgende Funktion dargestellt:

$$o = f(\underline{x}, \underline{w}, w_0) \quad (3.4)$$

Die Abbildung 3.4 zeigt die mathematische Modellierung eines Neurons. Die Berechnung des Neuronenausgangs  $o$  wird zweistufig berechnet. Ein Neuron kann  $R$  Eingänge besitzen. Es gilt  $[r \in \mathbb{N}^+ \mid r \leq R]$ . Jedem Eingang  $x_r$  wird genau ein Gewicht  $w_r$  zugeordnet.

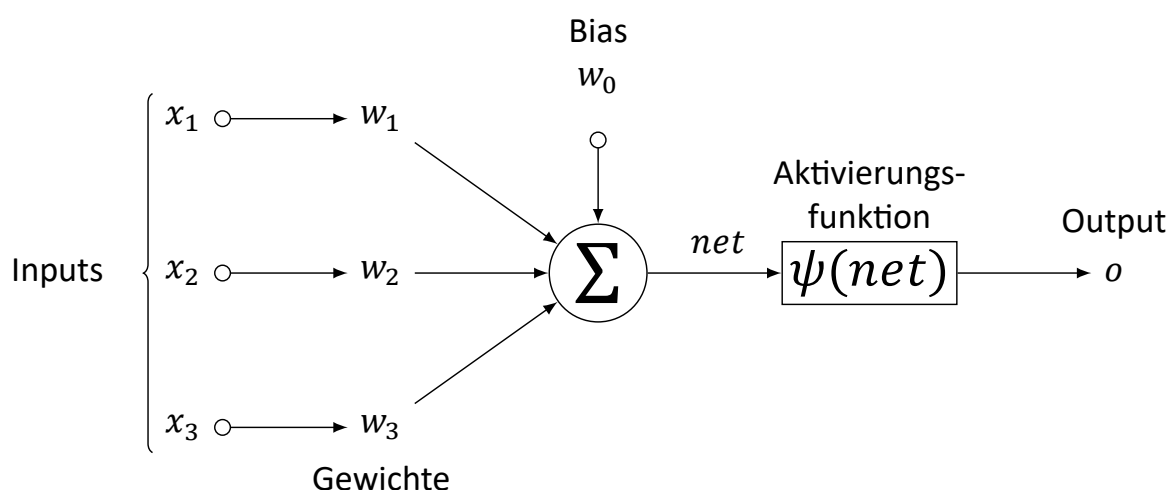


Abbildung 3.4: Künstliches Neuron mit 3 Eingängen

Im ersten Schritt werden die Eingänge mit ihren Gewichten multipliziert und anschließend aufsummiert. Die Höhe des Gewichts  $w_r$  gibt an, wie stark sich der Eingang  $x_r$  auf den Ausgang  $o$  auswirkt. Neben der Summe der gewichteten Eingänge wird zusätzlich das Biasgewicht  $w_0$  hinzugeaddiert. Der Bias Wert ermöglicht es, den Ausgang zu verschieben und dadurch mehr Funktionen abbilden zu können.

$$net = \sum_{r=1}^R w_r \cdot x_r + w_0 \quad (3.5)$$

Anschließend ergibt sich der Neuronenausgang  $o$  nach Gleichung 3.6, aus dem Netzeingang  $net$  und der gewählten Aktivierungsfunktion  $\psi$ . Die Aktivierungsfunktion kann als Schalter aufgefasst werden, der den Ausgang des Neurons schaltet. Es können unterschiedliche Aktivierungsfunktionen verwendet werden. Eine Darstellung einiger Funktionen ist in Kapitel 3.3.2 aufgeführt.

$$o = \psi(net) \quad (3.6)$$

### 3.3.2 Aktivierungsfunktionen

Die Aktivierungsfunktionen haben Einfluss auf die Genauigkeit und die Geschwindigkeit des Lernalgorithmus [KARL11]. Sie werden anwendungsspezifisch gewählt und können in den Schichten des Netzwerks unterschiedlich sein. Die Tabelle 3.1 zeigt eine Übersicht einiger Aktivierungsfunktionen.

Tabelle 3.1: Übersicht der Aktivierungsfunktionen

| Bezeichnung            | Formel                           | Ableitung   | Wertebereich                     |
|------------------------|----------------------------------|---|----------------------------------|
| Sigmoid                | $\psi(z) = \frac{1}{1 + e^{-z}}$ | $\frac{\partial \psi(z)}{\partial z} = \psi(z) \cdot (1 - \psi(z))$ | $\mathbb{R} \mapsto (0, 1)$      |
| Rectified Linear Units | $\psi(z) = \max(1, z)$           | $\psi(z) = \frac{1}{1 + e^{-z}}$                                    | $\mathbb{R} \mapsto [0, \infty]$ |
| Linear                 | $\psi(z) = z$                    | $\frac{\partial \psi(z)}{\partial z} = 1$                           | $\mathbb{R} \mapsto \mathbb{R}$  |
| Tangens hyperbolicus   | $\psi(z) = \tanh(z)$             | $\frac{\partial \psi(z)}{\partial z} = 1 - \psi(z)^2$               | $\mathbb{R} \mapsto (-1, 1)$     |

Die Sigmoidfunktion (3.5d) findet Anwendung in der Ausgangsschicht bei Klassifizierungsproblemen, da der Wertebereich  $[0, 1]$  ist. Die Tangens hyperbolicus (3.5c) zeigt in der Anwendung oft bessere Ergebnisse als die Sigmoid Aktivierung [KARL11]. Der Wertebereich ist auf  $[-1, 1]$  gegeben, dadurch werden die Daten um 0 zentriert. Die Rectified Linear Units Funktion ist bis zu dem Funktionswert 0 identisch 0 und steigt dann linear an. Daraus folgt, dass die Funktion nicht stetig ist und daher ist die Funktion nicht stetig differenzierbar. Die Ableitung der Funktion wird durch eine logarithmische Funktion approximiert. Bei Regressionsproblemen kommt in der Ausgabeschicht

die lineare Aktivierung zum Einsatz um eine Interpolation zu ermöglichen. Eine grafische Darstellung der Aktivierungsfunktionen ist in der Abbildung 3.5 zu finden.

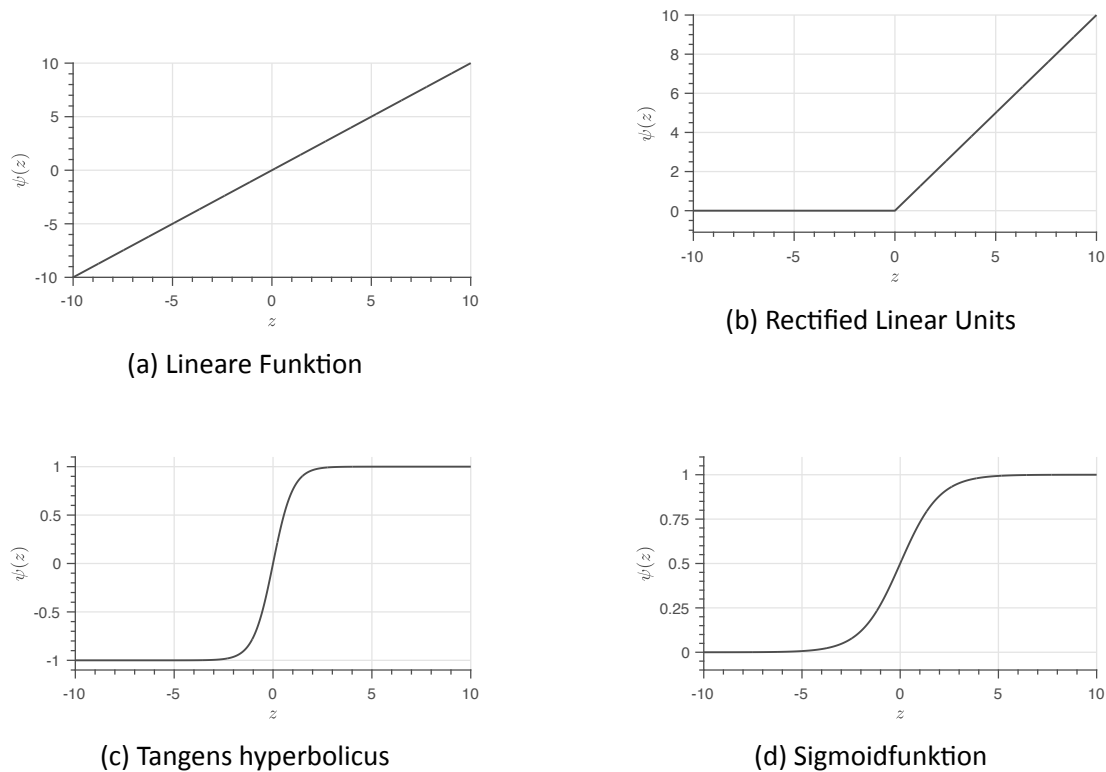


Abbildung 3.5: Aktivierungsfunktionen

### 3.3.3 Künstliche Neuronale Netzwerke

Der Zusammenschluss mehrerer Neuronen wird als Neuronales Netzwerk (NN) bezeichnet. Netzwerke können unterschiedliche Topologien aufweisen und sich in der Anzahl der Neuronen unterscheiden. Bei rekurrenten Netzen werden die Ausgänge der Neuronen wieder zurück in vorherige Neuronen geführt. Im Gegensatz zu rekurrenten Netzen sind bei Feedforward-Netzen Verbindungen der Neuronen ausschließlich mit der nächsten Schicht (in Richtung der Ausgabeneuronen) erlaubt [KRIE07]. Die Neuronen sind in Schichten eingeteilt. Ein Netzwerk besteht aus einer Eingabe- und einer Ausgabeschicht, sowie optional aus  $l$  verdeckten Schichten. Es gilt  $[l \in \mathbb{N}_0^+ \mid l \leq L]$ , wobei  $L$  die Anzahl der Schichten ist.

Die Abbildung 3.6 zeigt ein Netzwerk mit einer verdeckten Schicht. Jeder Kreis stellt ein Neuron dar. In dem gezeigten Netzwerk sind die Neuronen vollverknüpft. Die Eingangsschicht besteht aus fünf und die verdeckte Schicht aus drei Neuronen. In der Ausgabeschicht wird ein Neuron verwendet. Jedem Neuron werden die Gewichte  $w$  und der Typ der Aktivierungsfunktion eindeutig zugeordnet.




Abbildung 3.6: Neuronales Netzwerk mit einer verdeckten Schicht

Das in der Abbildung 3.6 dargestellte Netzwerk zählt zur Klasse der FeedForward-Netze. Das bedeutet, die Verbindungen der Neuronen sind nur in eine Richtung erlaubt. Ist das Netzwerk außerdem vollständig verknüpft spricht man von Multilayer-Perzeptron (MLP). In der vorliegenden Arbeit kommen ausschließlich MLP-Netzwerke zum Einsatz. Das MLP mit mindestens einer verdeckten Schicht hat den Vorteil ein universeller Approximator zu sein, welcher in der Regel mit einer geringen Anzahl von Parametern auskommt [DEFL11]. Durch den Einsatz von nichtlinearen Aktivierungsfunktionen können komplexe Funktionen approximiert werden. In [AHME10] wird gezeigt, dass sich besonders MLP zur Identifikation dynamischer Systeme eignen.

### 3.3.4 Forward Propagation

Die Berechnung des Ausgangs, auf Basis von Eingangsdaten, wird als Forward Propagation bezeichnet. Die gezeigte MLP Struktur besteht aus mehreren Neuronen, daher müssen die Gleichungen 3.5 und 3.6 erweitert werden. Jeder Verbindung im NN wird eine reelle Zahl als Gewicht  $w_{v,r}^l$  zugeordnet. Hierbei wird der Laufindex  $[l \in \mathbb{N}_0^+ \mid l \leq L]$  für die Nummerierung der einzelnen Layern verwendet. Der Index  $[v \in \mathbb{N}^+ \mid v \leq V_l]$  nummeriert die Neuronen in jeder Schicht. Dabei steht  $V_l$  für die Anzahl der Neuronen in der Schicht  $l$ . Der Netzeingang  $net_v^l$  des  $v$ -ten Neurons in der  $l$ -ten Schicht ergibt sich aus Gleichung 3.7. Dabei ist  $o_{v,r}^{l-1}$  der Ausgang des Neurons in der vorherigen Schicht des Netzwerkes. Die Summe wird dabei über den Index  $[r \in \mathbb{N}^+ \mid r \leq R_l]$  gebildet, dabei ist  $R_l$  die Anzahl der Neuronen in der Schicht  $l-1$ . Der Bias Wert  $w_{v,0}^l$  kann in die Summe integriert werden (Gleichung 3.7).

$$net_v^l = \sum_{r=1}^{R_l} w_{v,r}^l \cdot o_{v,r}^{l-1} + 1 \cdot w_{v,0}^l = \sum_{r=1}^{R_l+1} w_{v,r}^l \cdot o_{v,r}^{l-1} \quad (3.7)$$

$$o_v^l = \psi^l(\text{net}_v^l) \quad (3.8)$$

Die Gleichungen können zur Reduzierung der notwendigen Rechenoperationen in Vektorschreibweise dargestellt werden. Dadurch wird aus den Gewichten  $w_{v,r}$  eine Matrix der Dimension  $\mathbb{R}^{V_l \times R_l + 1}$ . Der Netzeingang  $\underline{\text{net}}^l$  und  $\underline{o}^l$  haben daher die Dimension  $\mathbb{R}^{R_l + 1}$ .

$$\underline{\text{net}}^l = \underline{\mathbf{W}}^l \cdot \underline{o}^{l-1} \quad (3.9)$$

$$\underline{o}^l = \psi^l(\underline{\text{net}}^l) \quad (3.10)$$

Die Forward Propagation Funktion wird bei der Nutzung von Neuronalen-Netzwerken häufig aufgerufen. Es ist daher eine möglichst effiziente Berechnung erforderlich. Für eine Implementierung, wie in den Gleichungen 3.9 und 3.10 dargestellt, wäre eine Iteration über alle Eingangsdaten  $[p \in \mathbb{N}^+ \mid p \leq P]$  notwendig. Daher wird die Berechnung noch weiter vektorisiert. Die Eingangsdaten spannen eine Matrix der Dimension  $\mathbb{R}^{V_0 + 1 \times P}$  auf. Daraus folgen die Gleichungen in Matrixdarstellung 3.11 und 3.12.

$$\underline{\mathbf{O}}^l = \psi^l(\underline{\mathbf{Net}}^l) \quad (3.11)$$

$$\underline{\mathbf{Net}}^l = \underline{\mathbf{W}}^l \cdot \underline{\mathbf{O}}^{l-1} \quad (3.12)$$

Es wird in jeder Schicht der Netzeingang nach Gleichung 3.13 und der Ausgang bestimmt. Dabei wird die Berechnung für jede Schicht  $l$  berechnet. Für die Eingangsschicht ( $l = 0$ ) gilt die Bedingung 3.13.

$$\underline{\mathbf{Net}}^0 = \underline{\mathbf{O}}^0 = \underline{\phi} \quad (3.13)$$

Zur Verdeutlichung der Berechnung wird die Matrixschreibweise vollständig in der Gleichung 3.14 dargestellt. Die Multiplikation gilt allgemein für die Schicht  $l$ . Es ist zu beachten, dass jeder Schicht  $l$  eine unterschiedliche Aktivierungsfunktion zugeordnet werden kann.

$$\underline{o}^l = \psi(\underline{\text{net}}^l) = \psi \left( \begin{bmatrix} w_{1,1}^l & w_{1,r}^l & \dots & w_{1,R}^l & w_{1,0}^l \\ w_{2,1}^l & w_{2,r}^l & \dots & w_{2,R}^l & w_{2,0}^l \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ w_{V,1}^l & w_{v,r}^l & \dots & w_{V,R}^l & w_{V,0}^l \end{bmatrix} \cdot \begin{bmatrix} o_{1,1}^l & o_{1,p}^l & \dots & o_{1,P}^l \\ o_{r,1}^l & o_{r,2}^l & \dots & o_{r,P}^l \\ \vdots & \vdots & \vdots & \vdots \\ o_{R,1}^l & o_{R,2}^l & \dots & o_{R,P}^l \\ 1 & 1 & \dots & 1 \end{bmatrix} \right) \quad (3.14)$$

### 3.3.5 Training

Die Gewichte des Neuronalen Netzes werden durch das sogenannte Training bestimmt. Ziel des Trainings ist es mit Hilfe von Trainingsdaten eine Lösung, für eine zuvor definierten Aufgabe, zu finden [KRUS11]. Bei dem Training von Neuronalen Netzen ist zwischen dem überwachten und unüberwachten Lernen zu unterscheiden. Bei dem überwachten Lernen sind die Zielwerte im Voraus nicht bekannt. Es liegen lediglich Eingangsdaten vor in denen Muster oder Strukturen erkannt werden sollen. Bei der Systemidentifikation liegt der Eingangs- und Ausgangsverlauf des Systems vor. Als Zielwert wird hier der Ausgangsgrößenverlauf verwendet. Dieses Problem wird auch als Regressionsproblem bezeichnet, bei dem das überwachte Lernen zum Einsatz kommt. Die Aufgabe des überwachten Lernens besteht darin das Netzwerk so zu trainieren, dass die Ausgangsdaten möglichst präzise approximiert werden. Dies wird erreicht indem die Gewichte so bestimmt werden, dass der Fehler der Fehlerfunktion minimiert wird. In jedem Trainingsschritt soll daher die Fehlerfunktion abnehmen [KRUS11].

Die Trainingsalgorithmen lassen sich in heuristische und gradientenbasierte Methoden einteilen. Die gradientenbasierten Verfahren im Bereich der Neuronalen Netze verwenden den Gradienten einer Zielfunktion, um die Gewichte des Netzwerks anzupassen. Die Anpassung der Gewichte erfolgt schrittweise und kann allgemein wie folgt definiert werden:

$$\underline{\mathbf{w}}_{i+1} = \underline{\mathbf{w}}_i - \Delta \quad (3.15)$$

Dabei wird der Schritt  $\Delta$  abhängig von dem gewählten Lernalgorithmus bestimmt. Nachfolgend wird der in der Arbeit verwendete Levenberg–Marquardt Algorithmus zum Training des Modells näher erläutert.

#### Levenberg–Marquardt Algorithmus

Wie dem Performancevergleich verschiedener Algorithmen in [KİŞİ05] und [HAGA94] zu entnehmen, liefert der Levenberg–Marquardt (LM) Algorithmus die besten Ergebnisse zur Lösung von Regressionsproblemen. In [YU11] wird gezeigt, dass der LM Algorithmus stabil und schnell läuft im Vergleich zu anderen Algorithmen. Die Schwierigkeit beim LM Verfahren liegt in der Berechnung der Jacobi-Matrix. Die Hesse-Matrix wird über die Jacobi-Matrix abgeschätzt. Um sicherzustellen, dass die Hesse-Matrix invertierbar ist, wird die in Gleichung 3.16 gezeigte Approximation verwendet. Dabei ist die  $J$  die Jacobi-Matrix,  $\mu$  der Kombinationskoeffizient und  $I$  die Einheitsmatrix. Die Diagonalelemente der Hesse-Matrix sind dadurch größer als 0 und dadurch ist die Matrix invertierbar.



$$\underline{\mathbf{H}} \approx \underline{\mathbf{J}}^T \cdot \underline{\mathbf{J}} + \mu \cdot \underline{\mathbf{I}} \quad (3.16)$$

Die Anpassung der Gewichte erfolgt schrittweise nach Regel 3.17. Über den Kombinationskoeffizient  $\mu$  kann zwischen den beiden Algorithmen gewechselt werden [YU11]. Ist der Koeffizient sehr klein (nahe 0), wird der Gauß-Newton Algorithmus verwendet. Ist der Koeffizient sehr groß, wird die Methode des steilsten Abstiegs verwendet.

$$w_{i+1} = w_i - (\underline{\mathbf{J}}_i^T \cdot \underline{\mathbf{J}}_i + \mu \cdot \underline{\mathbf{I}})^{-1} \cdot \underline{\mathbf{J}}_i \cdot \underline{\mathbf{e}}_i \quad (3.17)$$

Für die Berechnung der Hesse-Matrix  $\underline{\mathbf{H}}$  sind die zweiten Ableitungen notwendig. Die Berechnung der Ableitung zweiter Ordnung kann sehr rechenintensiv und komplex sein [YU11]. Daher wird die Hesse-Matrix durch die Jacobi-Matrix dargestellt. Dies hat zur Folge, dass nur noch die ersten Ableitungen der Fehlerfunktion  $e$  notwendig sind. Die Jacobi-Matrix  $\underline{\mathbf{J}}$  wird nach der Darstellung 3.18 definiert. Dabei ist  $V_L$  die Anzahl der Neuronen in der Ausgangsschicht [ $v \in \mathbb{N}^+ \mid v \leq V_L$ ] und  $p$  der Index über alle Trainingsdaten [ $p \in \mathbb{N}^+ \mid p \leq P$ ]. Die Gewichte werden in einem Vektor angeordnet dabei ist  $nw$  der Index über alle Gewichte [ $nw \in \mathbb{N}^+ \mid nw \leq NW$ ].

$$\underline{\mathbf{J}} = \begin{bmatrix} \frac{\partial e_{1,1}}{\partial w_1} & \frac{\partial e_{1,1}}{\partial w_2} & \frac{\partial e_{1,1}}{\partial w_{nw}} & \dots & \frac{\partial e_{1,1}}{\partial w_{NW}} \\ \frac{\partial e_{1,v}}{\partial w_1} & \frac{\partial e_{1,v}}{\partial w_2} & \frac{\partial e_{1,v}}{\partial w_{nw}} & \dots & \frac{\partial e_{1,v}}{\partial w_{NW}} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ \frac{\partial e_{1,V_L}}{\partial w_1} & \frac{\partial e_{1,V_L}}{\partial w_2} & \frac{\partial e_{1,V_L}}{\partial w_{nw}} & \dots & \frac{\partial e_{1,V_L}}{\partial w_{NW}} \\ \frac{\partial e_{p,1}}{\partial w_1} & \frac{\partial e_{p,1}}{\partial w_2} & \frac{\partial e_{p,1}}{\partial w_{nw}} & \dots & \frac{\partial e_{p,1}}{\partial w_{NW}} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ \frac{\partial e_{P,V_L}}{\partial w_1} & \frac{\partial e_{P,V_L}}{\partial w_2} & \frac{\partial e_{P,V_L}}{\partial w_{nw}} & \dots & \frac{\partial e_{P,V_L}}{\partial w_{NW}} \end{bmatrix} \quad (3.18)$$

### 3.3.6 Lernkurve

Die Anpassung der Gewichte erfolgt wie bereits gezeigt bei den gradientenbasierten Trainingsmethoden iterativ. Da die einzelnen Iterationen bei großen Datensätzen einen hohen zeitlichen Aufwand bedeuten ist es sinnvoll, den Fortschritt des Trainings zu überwachen [ANZA11]. Die Lernkurve ist eine Darstellung der Performance des Modells während des Trainings. Zur Bestimmung der Performance wird der Fehler des Modells in jeder Epoche bestimmt. Dieser Fehler lässt sich nach Gl. (3.19) aufteilen.

$$\underbrace{E \{(y_0 - \hat{y})^2\}}_{(\text{Modell-Fehler})^2} = \underbrace{E \{(y_0 - E\{\hat{y}\})^2\}}_{(\text{Bias-Fehler})^2} + \underbrace{E \{(\hat{y} - E\{\hat{y}\})^2\}}_{(\text{Varianz-Fehler})^2} \quad (3.19)$$

Der Modellfehler lässt sich nach Gl. (3.19) in den Bias- und den Varianzfehler unterteilen. Dieser Fehler wird während des Trainings auf unterschiedlichen Datensätzen bestimmt und in der Lernkurve dargestellt [ANZA11]. Die Kurven können zur Analyse des Trainingsfortschritts genutzt werden und geben Aufschluss über mögliche Probleme, welche während des Trainings auftreten können [GOOD16]. Die Abb. 3.7 zeigt eine beispielhafte Lernkurve. In der Darstellung wird der Fehler auf der y-Achse über den Trainings-Epochen auf der x-Achse aufgetragen.




Abbildung 3.7: Lernkurve

In der Abb. 3.7 sind zwei Kurven zu sehen. Die eine Kurve zeigt den Verlauf auf den Trainingsdaten und die andere Kurve beschreibt den Verlauf auf den Validierungsdaten. Diese zwei Datensätze werden vor dem Training aufgeteilt. Mit Hilfe von zwei unterschiedlichen Datensätzen ist es möglich das Problem der Über- oder Unteranpassung des Modells zu erkennen. Die Abb. 3.8 verdeutlicht den Unterschied der Anpassungen auf dem Trainingsdatensatz. In den Abbildungen werden die geschätzten Modellausgänge (gestrichelte Linien) und die Trainingsdaten (Punkte) dargestellt. Die y-Achse ist der Ausgang und die x-Achse ist der Eingang des Modells.




Abbildung 3.8: Darstellung der möglichen Anpassungen des Modells

Die Abb. 3.8a zeigt eine Unteranpassung des Modells auf den Trainingsdaten. Eine Unteranpassung liegt vor, wenn das Modell es nicht schafft die Trainingsdaten als Funktion abzubilden [KUBA15]. In der Abbildung ist beispielsweise eine lineare Interpolation der Daten nicht ausreichend um das Verhalten zu approximieren. In der Abb. 3.8b ist hingegen eine Überanpassung an die Daten zu erkennen. Wie zu sehen hat das Modell versucht alle Punkte möglichst genau zu treffen. Die Abb. 3.8c zeigt eine gute Anpassung an die Trainingsdaten. Das Modell approximiert den Verlauf der Trainingsdaten ohne sich an die Streuung der Messwerte anzupassen.

Es ist möglich die in der Abb. 3.7 gezeigte Lernkurve zur Analyse der Prüfung hinsichtlich der Über- und Unteranpassung zu nutzen [GOOD16]. Die Abb. 3.9 zeigt die Lernkurven für eine Über-, Unter- und Optimalanpassung.




Abbildung 3.9: Darstellung der Lernkurven für die möglichen Anpassungen des Modells

Eine Unteranpassung tritt auf, wenn das Modell nicht in der Lage ist einen ausreichend niedrigen Fehlerwert auf dem Trainingsdatensatz zu erzielen (siehe Abb. 3.9a). In der Abbildung ist zu erkennen, dass der Fehler auf dem Trainings- und Validierungsdaten nur gering abnimmt. Diese Unteranpassung kann auftreten wenn das Modell keine ausreichende Kapazität bietet, um den Verlauf abzubilden [ANZA11].

Das Gegenteil der Unteranpassung des Modells ist die Überanpassung an den Trainingsdatensatz. Die Abb. 3.9b zeigt die Lernkurve für den Fall der Überanpassung an den Trainingsdatensatz. In diesem Fall besitzt das Modell die notwendige Kapazität sich auch an Ausreißer und Messrauschen anzupassen [GOOD16]. Wie in der Abb. 3.8b zu sehen ist, besitzt der geschätzte Modellausgang einen geringen Abstand (Fehler) zu allen Trainingsdaten. Das führt zu einem geringen Fehler auf dem Trainingsdatensatz. In der Lernkurve (siehe Abb. 3.9b) ist zu erkennen, dass der Fehler auf dem Trainingsdatensatz stark fällt jedoch auf den Validierungsdaten mit zunehmender Anzahl an Epochen ansteigt. Den Start der Überanpassung ist charakterisiert durch den Anstieg des Fehlers auf dem Validierungsdatensatz [GOOD16]. Durch diese Überanpassung verliert das Modell seine Generalisierungsfähigkeit.

Bei der guten Anpassung fällt der Fehler auf den Trainings- und Validierungsdaten und es stellt sich ein stabiler Zustand ein [KUBA15]. Die Abb. 3.9c zeigt die Lernkurve für eine gute Anpassung. Es ist zu erkennen, dass für beide Datensätze der Fehler abnimmt. Stellt sich ein stabiler Zustand ein und das Modell wird weiter angepasst so kann es zu einer Überanpassung kommen [ANZA11]. Daher ist es notwendig das Training beim Erreichen des stabilen Zustands zu beenden.

### 3.4 Methoden der Hyperparameteroptimierung

Die Qualität des Modells hängt von der Wahl der Hyperparameter ab [VYAS19]. Unter Hyperparametern versteht man Parameter welche man bei der Erstellung des Modells anpassen möchte. Diese Parameter haben einen Einfluss auf die Güte des späteren Modells. Daher ist es notwendig diese bei dem Training zu optimieren. Beispielsweise können bei einem Multilayer Perceptrons (MLP) die Anzahl der Neuronen und die Anzahl der Schichten (beides diskrete Werte) optimiert werden. Auch wenn das Modell für das Problem gut geeignet ist, so kann eine schlechte Wahl der Hyperparameter in einer schlechten Modellperformance resultieren [JIMÉ07].

Um dies zu verhindern stehen verschiedene Methoden der Optimierung zur Verfügung. Allgemein lässt sich das Problem der Optimierung nach Gl. (3.20) formulieren. Hierbei stellt  $f()$  ein objektives Ergebnis (wie z. B. der RMSE) dar, welches auf dem Datensatz  $\chi$  minimiert werden soll. Dabei ist  $\Lambda$  die Menge von Hyperparametern, die auf dem Datensatz den kleinsten Fehler liefern soll.

$$\lambda^* = \underset{\lambda \in \Lambda}{\operatorname{argmin}} f(\lambda, \chi) \quad (3.20)$$

#### 3.4.1 Grid search Optimierung

Bei dem Grid search werden die optimalen Parameter auf einem Gitter in einen  $n_\lambda$ -dimensionalen Hyperparameterraum gesucht. Hierfür werden zunächst alle Parameter diskretisiert. In einigen Fällen, wie z. B. der Anzahl an Neuronen, ist der Parameter selbst bereits diskretisiert. Jedoch muss für manche Parameter, wie z. B. die Lernrate, eine Diskretisierung durchgeführt werden. [JIMÉ07]

Das Resultat der Hyperparameterdiskretisierung ist ein Gitter  $G$  von möglichen Parameterkombinationen. Dabei ist der  $i$ -te Parameter durch die Grenzen  $[a_i, b_i]$  und die Parameter Auflösungsgrenze  $\delta_i$  bestimmt. Das bedeutet der  $i$ -te Hyperparameter wird auf den Stützstellen  $\{a_i, a_i + \delta_i, \dots, a_i + H_i \delta_i\}$  mit  $H_i = (b_i - a_i) / \delta_i$  untersucht. Grafisch kann das Gitter  $G$  für zwei Hyperparameter wie in Abb. 3.10 zeigt dargestellt werden.




Abbildung 3.10: Hyperparameteroptimierung mit Hilfe von dem Grid search Verfahren

Mit dem aufgespannten Gitter wird das Modell erstellt und anschließend mit einer Kennzahl bewertet. Es wird die Parameterkonfiguration gewählt welche die Gl. (3.20) minimiert.

### 3.4.2 Random search Optimierung

In [BERG12] wird gezeigt, dass die Zufallssuche im Vergleich zu der manuellen- und Gittersuche effizienter ist. Die Performance des Modells hängt meist nur von wenigen Hyperparametern ab. Die Hyperparameter können jedoch mit hohem Einfluss von dem Trainingsdatensatz abhängen. Die Gittersuche ist daher eine schlechte Wahl beim Training für neue Datensätze. [BERG12]

Wie auch bei dem Grid search-Verfahren werden bei dem Random search-Verfahren die Hyperparameter innerhalb eines definierten Parameterraums optimiert. Daher wird hier auch der  $i$ -te Parameter durch die Grenzen  $[a_i, b_i]$  bestimmt. Der  $i$ -te Parameter  $\lambda_i$  wird im Vergleich zu dem Grid search innerhalb der Grenzen zufällig gewählt. Die Abb. 3.11 zeigt eine Optimierung der 2-d Hyperparameter mit Hilfe des Random search Verfahren.




Abbildung 3.11: Hyperparameteroptimierung mit Hilfe von dem Random search Verfahren

In der Darstellung werden alle Hyperparameterkombinationen  $\lambda^k = (\lambda_1^k, \lambda_2^k)$  mit  $[k \in \mathbb{N}_0^+ \mid k \leq n_\lambda]$  gezeigt, wobei  $n_\lambda$  die Anzahl der gewählten Iterationen ist. Das Modell wird für alle Kombinationen  $\lambda^k$  erstellt und auf einem Validierungsdatensatz mit einer Kennzahl bewertet und anschließend wird die bestbewertete Kombination  $\lambda^*$  gewählt.

### 3.4.3 Bayesian Optimierung

Die Bayesian Optimierung stellt die State of the Art Methode zur Hyperparameteroptimierung dar [KLE16]. Im Gegensatz zu der Grid und der Random search Verfahren werden bei dieser Methode die vergangenen Evaluationen bei jeder Iteration mit einbezogen. Hierzu wird ein Wahrscheinlichkeitsmodell  $P(x \mid y)$  erzeugt, welches von den Hyperparametern auf die Wahrscheinlichkeit der Auswertung der Zielfunktion abbildet. Das Wahrscheinlichkeitsmodell:

$$P(\text{Wert der Zielfunktion} \mid \text{Hyperparameter}) \quad (3.21)$$

ist im Vergleich zu der Zielfunktion einfacher zu optimieren [KLE16]. Daher werden in jeder Iteration Hyperparameter gewählt, welche die größte Wahrscheinlichkeit besitzen, die Zielfunktion zu minimieren. Anschließend wird das Modell mit diesen Parametern trainiert und die Zielfunktion mit dem trainierten Modell ausgewertet. Nun wird der wahre Wert der Zielfunktion mit dem geschätzten Wert des Wahrscheinlichkeitsmodells verglichen. Mit diesem Ergebnis wird das Wahrscheinlichkeitsmodell angepasst und dadurch steigt die Güte der Vorhersage mit steigender Anzahl an Iterationen. Dieser Vorgang wird solange wiederholt, bis die maximale Anzahl an Iterationen erreicht ist. Anschließend werden die Hyperparameter gewählt welche die besten Ergebnisse auf der Zielfunktion erreicht haben. Die Abb. 3.12 zeigt das Wahrscheinlichkeitsmodell für zwei unterschiedliche Anzahl an Iterationen.

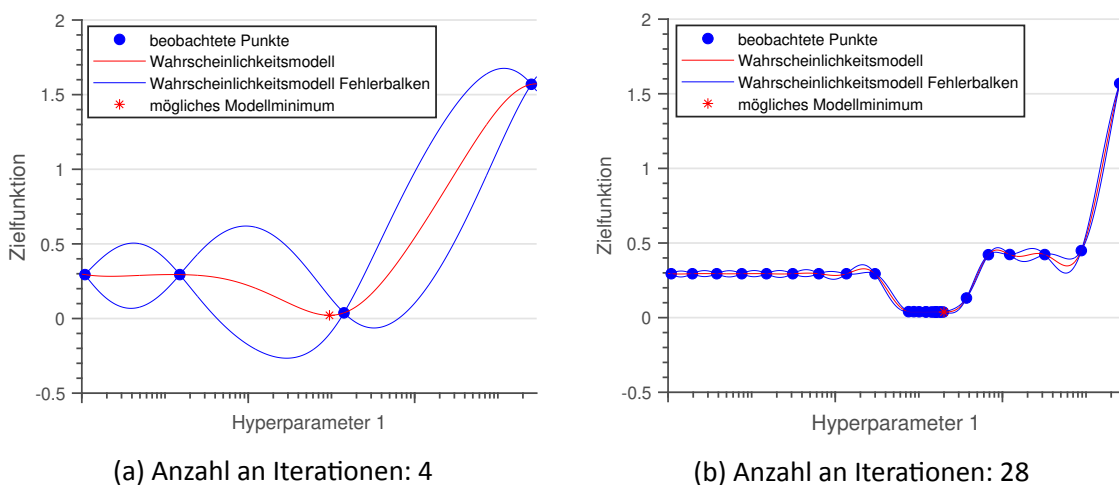


Abbildung 3.12: Modell der Bayesian Optimierung

Die Darstellung beschränkt sich auf einen Hyperparameter, was eine zweidimensionale Darstellung möglich macht. Auf der x-Achse wird der Wert für den ersten Hyperparameter dargestellt und auf der y-Achse die Werte der Zielfunktion. In der Abb. 3.12 stellen die blauen Punkte die beobachteten Werte dar. Diese zeigen die Auswertungen der Zielfunktion mit dem trainierten Modell und die rote Linie stellt die Approximation des Kurvenverlaufs durch die beobachteten Werte mit Hilfe des Wahrscheinlichkeitsmodells dar. Die Wahrscheinlichkeit der Vorhersage wird über die Fehlerbalken dargestellt. Es ist zu erkennen, dass die Fehlerbalken mit zunehmender Anzahl an Iterationen kleiner werden. Dadurch steigt die angesprochene Güte des Modells durch die Zunahme der Evaluationen. Vergleicht man das Wahrscheinlichkeitsmodell nach 4 Iterationen (Abb. 3.12a) mit dem Modell nach 28 Iterationen (Abb. 3.12b), so ist eine Verbesserung der Wahrscheinlichkeit der Vorhersage des Modells zu erkennen. Dadurch ist es nach 28 Iterationen wahrscheinlicher Hyperparameter vorherzusagen, welche gute Ergebnisse auf Zielfunktion liefern.

## 4 Versuchsplanung und Durchführung

In dem vorherigen Kapitel wurden die Grundlagen der Modellierung mit Hilfe von datenbasierten Methoden erläutert. Dieses Kapitel beschäftigt sich mit der Planung, Durchführung und Analyse der Daten, welche für die datenbasierte Modellierung notwendig sind. Die Güte des späteren Modells wird durch die zur Verfügung stehenden Daten bestimmt, daher ist es notwendig die Datengenerierung im Vorfeld zu planen [NELL13, SJÖB95, LJUN99]. Die für die datenbasierten Methoden notwendigen Versuche werden in diesem Kapitel näher dargestellt und die Ergebnisse diskutiert. Allgemein ist es notwendig, dass die Trainingsdaten reich an Informationen sind. Sind die Daten nicht reich an Informationen, so kann das erzeugte Modell keine gute Modellperformance bieten [WANG11]. Um die Einschränkungen der Modellgüte in Bezug auf die vorhandenen Daten zu reduzieren, wird eine Versuchsplanung durchgeführt.

Im Rahmen dieser Planung sind gewisse Randbedingungen zu treffen, die Anregungssignale zu wählen und die Abtastzeit festzulegen [BOHN16]. Nachfolgend werden zunächst die Systemgrenzen definiert der Versuchsaufbau erläutert. Für die Aufnahme der erforderlichen Messdaten ist es notwendig einen definierten Versuchsaufbau zu verwenden um eine Reproduzierbarkeit zu garantieren, daher werden die beachteten Aspekte während der Versuchsdurchführung erläutert. Und darauf aufbauend unterschiedliche Anregungssignale diskutiert. Die erzeugten Daten sind nicht frei von Störungen, daher ist notwendig die Daten vor der Weiterverarbeitung aufzubereiten [BEUC19]. Der Unterabschnitt 4.3 zeigt die dafür verwendeten Methoden und entwickelten Filter. In dem letzten Abschnitt 4.4 dieses Kapitels, werden die aufgenommenen Daten für die unterschiedlichen Anregungssignale verglichen (im Bezug auf die Aufgabenstellung).

### 4.1 Versuchsplanung für datenbasierte Modellierung

Für die Modellierung des Systemverhaltens ist es erforderlich Daten des Systems zu erfassen. Die dafür notwendigen Versuche sind zeit- und kostenintensiv. Es ist daher sinnvoll den Versuch vorher zu planen und zu entscheiden, welche Signale gemessen und wie das System angeregt werden soll. Das Ziel der Versuchsplanung ist es, die Entscheidungen so zu treffen, dass der Informationsgehalt des Datensatzes (unter Berücksichtigung der Randbedingungen) maximal ist [LJUN99]. Neben dem Amplitudenbereich ist es notwendig auch die Frequenzen des Systems außerhalb des Gleichgewichts anzuregen [GUTJ12].



Bei dem Bagger handelt es sich um ein Mehrgrößensystem mit mehreren Eingangs- und Ausgangsgrößen (MIMO). Die Eingangsgrößen des Systems sind die Joystickwerte der einzelnen Zylinder. Wie in dem Kapitel 2.5.1 erklärt, wird jeder Achse des Joysticks ein Hydraulikzylinder zugeordnet. Die Änderung der Joysticksignale (Eingangsgrößen) führen zu einer Änderung der Geschwindigkeit (Ausgangsgrößen) der einzelnen Zylinder. Die Abb. 4.1 zeigt das Blockschaltbild der Datengenerierung




Abbildung 4.1: Blockschaltbild Datengenerierung

Es ist zu erkennen, dass während der Datengenerierung ein Joysticksignal von dem Joystick Generator vorgeben wird. Dieser Generator hat die Aufgabe eine sichere Bewegung zu garantieren und die definierten Randbedingungen und Restriktionen einzuhalten. Er kann Signale generieren, welche sich wie in der Abb. 4.2 einteilen lassen.




Abbildung 4.2: Mögliche Art der Signalgenerierung

Die Signale können entweder manuell oder automatisch generiert werden (siehe Abb. 4.2). Ein manuelles Signal ist beispielsweise die Datengenerierung während des normalen Betriebs. Diese Signale sind zwar einfach aufzunehmen, jedoch ist es nicht möglich die Ergebnisse zu reproduzieren. Eine Anforderung an die Strategie ist die Übertragbarkeit auf einen anderen Bagger. Daher werden im Rahmen der Arbeit nur Signale verwendet welche automatisch generiert werden. Die Signale lassen sich weiterhin wie in der Abb. 4.2 dargestellt, in Einzelachs-bewegungen und Mehrachs-bewegungen unterteilen. Es wird von Mehrachs-bewegungen gesprochen, wenn mehr als ein Zylinder während der Aufnahme der Daten bewegt wird. Aufgrund der aufwendigen Applikation und Absicherung von Mehrachs-bewegungen liegt der Fokus der Arbeit bei Einzelachs-bewegungen. Diese ermöglichen eine effiziente Übertragbarkeit auf andere Maschinen und sind einfacher

zu applizieren. Die Untersuchungen beschränken sich zunächst auf den Auslegerzylinder und werden anschließend auf den Stielzylinder übertragen.

### 4.1.1 Systemgrenzen

Bei der Versuchsplanung ist es erforderlich gewisse Systemgrenzen anzunehmen, um das Modell an den für die Anforderungen notwendigen Bereich anzupassen [WANG11]. Da es schwierig ist ein genaues globales Modell zu erzeugen, wurde in [WOLP98, PETK06, PETR14] die aufgaben und kontextbezogene Modellierung von Inversen dynamischen Modellen untersucht. Dabei hat sich gezeigt, dass die Anpassung des Modells an einen Kontext (beziehungsweise an eine Aufgabe) eine Steigerung der Modellgüte mit sich bringt. Dies kann auf die Vereinfachung des Lernprozesses zurückgeführt werden. Um diese Vorteile zu nutzen, wird nachfolgend der Kontext für die inverse datenbasierte Modellierung definiert. Dieser Kontext lässt sich durch Systemgrenzen beschreiben. Die Grenzen können zum einen physikalische Limitierungen des Systems sein oder zum anderen gewählte kontextbezogene Beschränkungen. Nach [ISER10] können diese Grenzen in die folgenden vier Arten unterteilt werden:

1. Die verfügbare Messzeit  $T_M$  ist nach Gl. (4.1) limitiert, entweder durch die technischen Einschränkungen oder aufgrund der Wirtschaftlichkeit.

$$T_M < T_{M,max} \quad (4.1)$$

2. Das Eingangssignal  $u(t)$  ist begrenzt. Zum Beispiel ist es meist notwendig die Auslenkung des Signals  $u(t)$  auf einen gewissen Arbeitsbereich  $[u_{min}, u_{max}]$  wie in Gl. (4.2) dargestellt zu begrenzen, da das System wegen der physikalischen Limitierung keine beliebigen Eingangssignale verarbeiten kann.

$$u_{min} < u(t) < u_{max} \quad (4.2)$$

3. Das Eingangssignal  $u(t)$  führt zu einer Änderung der Ausgangsgröße  $y(t)$ . Diese kann durch die physikalischen Eigenschaften des Systems auf einen Bereich  $[y_{min}, y_{max}]$  nach Gl. (4.3), oder auf einen Bereich mit linearem Verhalten des Systems begrenzt sein.

$$y_{min} < y(t) < y_{max} \quad (4.3)$$

4. Neben den Eingangs- und Ausgangsgrößen müssen auch die Limitierungen der Zustände beachtet werden. Zum Beispiel können hier Beschränkungen  $[x_{min}, x_{max}]$  von Anstiegsraten notwendig sein um ein gewisses Verhalten zu beschränken.

$$x_{min} < x(t) < x_{max} \quad (4.4)$$

### Zeitlimitierung

Da es sich in dieser Arbeit bei dem untersuchten Versuchsträger um einen Bagger handelt, welcher nur für Versuchszwecke eingesetzt wird, ist es möglich verschiedene Strategien zu evaluieren. Das Ziel dabei ist eine möglichst effektive Strategie zu entwickeln, welche sich auch auf andere Fahrzeuge übertragen lässt. Heutige Bagger werden nach ihrer Fertigstellung aufwendig in Betrieb genommen. Hierzu werden die Ventilkanten der Hydraulikventile iterativ angepasst, bis das Baggerverhalten den gewünschten Anforderungen entspricht. Bei diesem Prozess wird ein Ventilkennfeld appliziert. Im Rahmen von dieser Applikation wäre es möglich auch die Daten für die datenbasierte Modellierung zu generieren. Der notwendige Zeithorizont zur Datengenerierung soll daher bei einem Zeithorizont von wenigen Stunden liegen. Die verfügbare Messzeit  $T_M$  wird auf  $T_M \leq 2$  h pro Achse begrenzt.

### Eingangslimitierung

In den Versuchen wird als Eingangsgröße des Systems ein Joystickwert in ‰ vorgegeben. Dieses Joysticksignal wird von einem Signalgenerator berechnet und per Controller Area Network (CAN) an die Betriebssteuerung gesendet. Das Signal kann für jeden Zylinder einen Wert zwischen  $-1000$  ‰ und  $1000$  ‰ annehmen. Ein negativer Wert entspricht einer negativen Geschwindigkeit und ein positiver einer positiven Geschwindigkeit. Bei einem Joystickwert von  $0$  ‰ befindet sich der Zylinder im statischen Fall in Ruhelage. Um den Mehrwert der kontextbezogenen Datengenerierung zu nutzen wird, für jeden Zylinder ein maximaler Wert für das Joysticksignal definiert.

Die Tab. 4.1 zeigt die Limitierung des Joysticksignals für jeden Zylinder. Es ist zu erkennen, dass für den Stielzylinder höhere Werte erlaubt sind, da der Stielzylinder einen dominanteren Anteil bei einer typischen Planziehbewegung mit wenig Steigung besitzt (hinsichtlich der auftretenden Geschwindigkeiten und dem dementsprechenden Joysticksignal). Daher wird der Wert für den Stielzylinder höher gewählt.

Tabelle 4.1: Eingangslimitierung des Joysticksignals bei der Datengenerierung


| Achse    | Wert    |
|----------|---------|
| Ausleger | $800$ ‰ |
| Stiel    | $850$ ‰ |

Neben einer Limitierung des maximalen Joysticksignals ist es notwendig das Eingangssignal auf einen minimalen stationären Wert zu beschränken. Aufgrund von der Reibung der Zylinder und des hydraulischen Systems sowie der Betriebssteuerung, kommt es bei kleinen Joystickwerten nicht direkt zu einer Bewegung der Zylinder. Dieses Verhalten tritt bei der Bewegung aus der Ruhelage auf, da hier zunächst die Haftreibungsgrenze überschritten werden muss. Damit dieses Verhalten


möglichst in den Trainingsdaten vermieden wird, wird ein minimales stationäres Joysticksignal von 50 ‰ festgelegt.

### Ausgangslimitierung

Als Ausgang der Strecke wird die Geschwindigkeit der einzelnen Zylinder angenommen. Eine Limitierung dieser Größe ergibt sich einerseits aus der physikalischen Limitierung des Systems und andererseits durch die Limitierung der Eingangsgröße des Systems. Daher ist es notwendig zu überprüfen, ob die für die Eingangslimitierung getroffenen Restriktionen für die später auftretenden Geschwindigkeiten der einzelnen Zylinder ausreichend sind. Von einem geübten Baggerfahrer werden manuell schnelle Planziehbewegungen durchgeführt und die auftretenden Joystickwerte aufgezeichnet. Die Abb. 4.3 zeigt die aufgezeichneten Ergebnisse der Planziehbewegung.



(a) Auslegerzylinder



(b) Stielzylinder

Abbildung 4.3: Geschwindigkeitsverlauf bei Planziehbewegungen

In der Abb. 4.3a der Verlauf des Auslegerzylinders und in Abb. 4.3b der Verlauf des Stielzylinders dargestellt. Die Geschwindigkeiten der jeweiligen Zylinder werden auf der linken y-Achse und die dazugehörigen Joystickwerte auf der rechten y-Achse dargestellt. Betrachtet man den Signalverlauf so fällt auf, dass die Joysticksignale unterhalb der maximalen Grenzwerte liegen. Außerdem ist

dem Geschwindigkeitsverlauf zu entnehmen, dass die Zylinder sich ohne schnelle Schwingungen bewegen.

Sind die Anregungen zu dynamisch, so werden die Schwingungen auf den Oberwagen übertragen. Das gesamte Fahrzeug fängt dadurch an zu schwingen und die Schwingungen schlagen sich auch in den gemessenen Signalen nieder. Damit diese Schwingungen in den Versuchsdaten verhindert werden, wird eine Filterung des Eingangsjoysticksignals durchgeführt. Durch diese Filterung treten die Schwingungen nicht in den Trainingsdaten auf und werden deswegen auch nicht von dem Systemmodell erlernt. Als Filterübertragungsfunktion wird die in Gl. (4.5) gezeigt Übertragungsfunktion verwendet.

$$G_F^{Jystk} = \frac{1}{T_F^{Jystk} s + 1} \quad (4.5)$$

Mit Hilfe dieses Filters kommt es zu einer Dämpfung der hochfrequenten Anteile des Joysticksignals. Die Dämpfung führt zu geringeren Schwingungen der Geschwindigkeit im Zeitbereich. Die Zeitkonstante des Filters  $T_F^{Jystk}$  kann aus einer Fourier-Transformation der Joysticksignale während einer natürlichen Planziehbewegung abgeschätzt werden. Die Abb. 4.4 zeigt die Ergebnisse der Fourier-Transformation der Joysticksignale.




Abbildung 4.4: Fourier-Transformation der Joysticksignale bei Planziehbewegungen

In Abb. 4.4 ist die normierte Stärke der Spektralen Anteile der Joysticksignale auf der y-Achse über der Frequenz in Hz auf der x-Achse gezeigt. Beide Fourier-Transformationen zeigen, dass die Signalanteile unterhalb von 4 Hz liegen. Aus dieser Grenzfrequenz, ergibt sich eine Zeitkonstante für die Übertragungsfunktion (Gl. (4.5)) von  $T_F^{Jystk} = 0,25$ . Diese Annahme wird außerdem dadurch gestützt, dass der Regler im späteren Einsatz einer Solltrajektorie mit dem Verhalten ähnlich zu der Dynamik der Filterübertragungsfunktion verarbeitet.

### Zustandslimitierung

Neben den Systemgrenzen hinsichtlich der Eingangs- und Ausgangslimitierung werden auch bestimmte Systemzustände auf einen Kontext begrenzt. Betrachtet man sich den späteren Arbeitsbereich des Baggers, in dem die Automatisierungsfunktionen genutzt werden sollen, so lässt sich der Bereiche durch eine maximale und minimale Höhe des TCP begrenzen. Die Abb. 4.5 zeigt die Limitierung des Arbeitsbereiches.




Abbildung 4.5: Arbeitsraumbegrenzung

Da die Assistenzfunktionen primär bei Arbeiten unterhalb der Kabinenhöhe genutzt werden, ist es nicht notwendig Daten außerhalb dieser Systemgrenzen zu generieren. Gerade bei Armstellungen, bei denen der TCP weit oberhalb der Kabine liegt, treten (aufgrund der kinematischen Kette) Systemzustände auf die in dem späteren Kontext des autonomen Baggers nicht auftreten. Daher beschränken sich die Versuche auf einen definierten Arbeitsbereich. Die Abb. 4.5 zeigt die definierten Grenzen für den Arbeitsbereich. Es ist zu erkennen, dass der Arbeitsraum in der Höhe begrenzt ist. Als maximale Höhe des TCP wird  $z_{TCP} < 3 \text{ m}$  gewählt. Die Entfernung von TCP zu dem Bagger wird durch die physikalischen Grenzen der kinematischen Kette beschränkt. Die Versuche beschränken sich im Rahmen der Arbeit auf die dargestellte Ebene. Eine Drehung des Oberwagens wird nicht näher untersucht.

#### 4.1.2 Festlegung der Abtastzeit

Bei der Wahl der Abtastzeit spielt der Frequenzbereich des Systems, welcher vom Modell abgedeckt werden soll, eine entscheidende Rolle. Aus Sicht der Signalverarbeitung muss die Abtastfrequenz  $f_s$  mindestens zweimal so groß wie die maximale Spektralfrequenz des Signals sein. Das Abtasttheorem Gl. (4.6) stellt sicher, dass das Signal aus der zeitdiskreten Abtastung wieder rekon-

struiert werden kann [BEUC19]. Die Abtastung der Signale muss dann ausreichend schnell erfolgen, damit die höchsten auftretenden Frequenzen noch unterhalb der Frequenz  $f_s$  liegen.

$$f_s \geq f_{max} \quad (4.6)$$

Die Abb. 4.6 zeigt das Amplitudenspektrum der Geschwindigkeit des Stielzylinders einer Voruntersuchung. Auf der y-Achse ist der Betrag des Amplitudenspektrums und auf der x-Achse die Frequenz dargestellt. Betrachtet man den Verlauf so fällt auf, dass eine maximale Spektralfrequenz  $f_{max}$  von 15 Hz angenommen werden kann, da ab diesem Wert keine nennenswerten Spektralanteile auftreten. Daher ergibt sich mit der Gl. (4.6) eine notwendig Abtastfrequenz  $f_s$  aus Sicht der Signalverarbeitung von 30 Hz.




Abbildung 4.6: Amplitudenspektrum der Geschwindigkeit

Neben der Betrachtung aus Sicht der Signalverarbeitung spielt der Einsatz des identifizierten Modells bei der Wahl der Abtastzeit eine Rolle. Da das Modell später in einem zeitdiskreten Regler verwendet wird, sollte die Abtastzeit für die Identifikation des Regelkreises entsprechen [WANG11]. Dieser kann aus der notwendigen Dynamik der Solltrajektorie bestimmt werden. Das dynamische Verhalten der Solltrajektorie kann näherungsweise durch ein System erster Ordnung mit der Übertragungsfunktion:

$$G(s) = \frac{K}{Ts + 1} \quad (4.7)$$

beschrieben werden. Die dominante Zeitkonstante  $T$  in Gl. (4.7) wird mit einem Wert von 0.25 angenommen. Dadurch ergibt sich eine 3dB-Bandbreite  $\omega_b$  nach Gl. (4.8) von 4 Hz. Diese Frequenz gibt die Grenzfrequenz an, bei der die Amplitude der Übertragungsfunktion um 3 dB abfällt.

$$\omega_b = \frac{1}{T} \quad (4.8)$$

Die notwendige Abtastzeit kann mit Gl. (4.9) und der berechneten Bandbreite  $\omega_b$  abgeschätzt werden [BOHN16].

$$f_s \approx (17 \dots 29) \omega_b \quad (4.9)$$

Mit der angenommen dominanten Zeitkonstante  $T = 0.25$  ergibt sich eine Abtastzeit zwischen 68 Hz und 116 Hz. Für die Versuche wird daher eine Abtastfrequenz von 100 Hz festgelegt.

### 4.1.3 Versuchsdurchführung

Um eine Wiederholbarkeit der Versuche zu garantieren ist es notwendig, bei jedem Versuch den identischen Versuchsaufbau zu wählen. Der Bagger wird während der Versuche auf einem festen Untergrund platziert und das Schild sowie die hinteren Stützen ausgefahren. Das Ausfahren der Stützen ist notwendig, um einen stabilen Kontakt mit dem Boden herzustellen und die reduzierte Stabilität durch die Reifen von Mobilbaggern zu kompensieren.

Weiterhin ist es erforderlich den Ölkreislauf für die Versuche vorzubereiten. Die Viskosität des Hydrauliköls hat einen Einfluss auf das Systemverhalten des Baggers. Ändert sich die Temperatur des Öls, so ändert sich die dynamische Viskosität des Öls. Bedingt durch diesen Zusammenhang ist es erforderlich das Hydrauliksystem auf die Betriebstemperatur zu bringen. Hat das Öl die Betriebstemperatur von etwa 75 °C erreicht, wird die Öltemperatur durch einen Kühlkreislauf etwa konstant gehalten. Somit können die Auswirkungen durch die Änderungen der dynamischen Viskosität des Öls ausgeschlossen werden. Der Versuchsträger bietet mehrere Betriebsmodi und Nenndrehzahlen zur Auswahl. Für alle Versuche wird eine Nenndrehzahl von 1800/min festgelegt. Durch die Änderung der Modi wird die Betriebsstreuung angepasst und das Systemverhalten der Strecke ändert sich. Dies hat zur Konsequenz, dass das Modell nur eine Gültigkeit für einen Betriebsmodus besitzt.

Neben dem Eingangs- und Ausgangsverhalten der Strecke spielen die auftretenden Drücke eine wichtige Rolle. Das Druckniveau hat einen Einfluss auf das Systemverhalten. Das Druckniveau ändert sich durch Änderung der Last welche auf jeden einzelnen Zylinder wirkt. Die Last kann einerseits über die Änderung der Masse in der Schaufel und andererseits durch die Änderung der Baggerarmposition geändert werden. Das Druckniveau über die Stellung des Baggerarms einzustellen hat den Vorteil einfach umsetzbar zu sein. Ist der Baggerarm beispielsweise vollständig ausgefahren so wirkt auf den Ausleger- und Stielzylinder (aufgrund des größeren Hebelarms) eine höhere Last, was zu einem Anstieg des LS Drucks führt und dementsprechend die Druckdifferenz ändert.



Diese Änderung wirkt sich auf den Zusammenhang von dem Joysticksignal und Geschwindigkeit des Zylinders aus. Das hinzufügen einer externen Last hat den Vorteil einen breiten Druckbereich abzudecken, allerdings erhöht sich dadurch der notwendige Versuchsaufbau.

Damit unterschiedliche Druckniveaus in Versuchsdaten abgebildet werden können, werden daher die Anregungssignale für unterschiedliche Entfernungen des TCP wiederholt. Die Abb. 4.7 zeigt die Unterteilung des Arbeitsbereiches für die Messungen des Auslegerzylinders.




Abbildung 4.7: Unterteilung Arbeitsbereich

In Abb. 4.7 sind die Positionen des TCP in z-Richtung über der Position in x-Richtung gezeigt. Dabei gibt die z-Richtung die Höhe über dem Boden und die x-Richtung die Entfernung vom Schwerpunkt des Baggers an. Es ist zu erkennen, dass sich der TCP in einer Kreisbahn bewegt. Der Bahnverlauf ergibt sich durch die kinematische Verkettung der einzelnen Achsen. Die Anregungssignale werden nur auf eine Einzelachse appliziert und die anderen Zylinderachsen werden währenddessen konstant gehalten. Für die Messungen des Auslegerzylinders wird die Entfernung des TCP über den Stielzylinder eingestellt. Ist der Stielzylinder vollständig ausgefahren so ist die Entfernung zum Bagger minimal und ist der Stielzylinder vollständig eingefahren so ist der TCP maximal entfernt. In der Abb. 4.7 sind beide Extremwerte sowie zusätzliche Messungen zwischen den beiden Extremwerten dargestellt. Wie in der Abbildung zu sehen, werden die Messungen an den Extremwerten und an unterschiedlichen Positionen zwischen den Extremwerten durchgeführt.

## 4.2 Anregungssignale

Der Zweck des Anregungssignales ist es die Eingangs- und Ausgangsdaten des Systems so zu generieren, dass sie genügend Informationen für das datenbasierte Systemmodell bereitstellt, um die nichtlineare Prozessdynamik für den ganzen Arbeitsbereich abzudecken [DOHE97]. Bei nichtlinearen Systemen gilt das Superpositions- und Homogenitätsprinzip nicht. Dadurch sind die Systemeigenschaften, wie Dämpfung und Streckenverstärkung, von der Amplitudenhöhe des Eingangs-

signals abhängig. Daraus folgt, dass die Anregungssignale ein hinreichend breites Spektrum an Amplitudenhöhen bereitstellen sollen. [JELA12] Die Literatur [BOHN16, JELA12, DEFL11] empfiehlt folgende Anregungssignale für die Identifikation von nichtlinearen dynamischen Systemen:

- Chirp
- Amplitudenmoduliertes pseudo-random binäres Rauschsignal
- Sprünge

Diese werden nachfolgend näher diskutiert und vorgestellt. Im nächsten Kapitel werden die Auswirkungen der Signale auf die Modellierung näher untersucht.

### 4.2.1 Chirp

Bei dem Chirp-Signal handelt sich um ein Sinus-Signal bei dem sich die Frequenz zeitlich ändert. Dabei wird zwischen einem negativen Chirp (Frequenz nimmt mit der Zeit ab) und einem positiven Chirp (Frequenz nimmt mit der Zeit zu) unterschieden. Das Signal lässt sich durch die Gleichung Gl. (4.10) beschreiben.

$$u(k) = u_0 + Amp \cdot \sin(\omega_k k T_0) \quad (4.10)$$

Das Signal lässt sich durch den Offset, die Amplitude und den Verlauf der Frequenz charakterisieren. Wird das Signal als Anregung bei nicht linearen Systemen verwendet so ist es notwendig, die Messung mit unterschiedlichen Offsets  $u_0$  und Amplituden  $Amp$  zu wiederholen [JELA12].

Bei der harmonischen Anregung durch das Chirp Signal werden nur dynamische Bereiche in den Trainingsdaten abgedeckt. Es gibt keine Bereiche in denen sich das Joysticksignal für eine gewisse Haltezeit nicht ändert. Dadurch kann das datenbasierte Modell den statischen Zusammenhang zwischen dem Joystick und der Geschwindigkeit nicht direkt lernen. Es ist zu erwarten, dass das Modell Probleme in den statischen Bereichen aufzeigt, aber den dynamischen Bereich gut abdeckt.

### 4.2.2 Amplitudenmoduliertes pseudo-random binäre Sequenz

Bei dem Amplitudenmoduliertes pseudo-random binäre Sequenz (APRBS) handelt es sich um eine Reihe von Sprüngen mit unterschiedlichen Haltezeiten. Das Signal ist ein periodisch deterministisches Signal, mit den Eigenschaften ähnlich dem weißen Rauschen [TAN01]. Die Amplituden des Signals sind frei zu wählende Werte im Eingangsraum [DEFL11]. Die Funktion lässt sich als Stufenfunktion nach Gl. (4.11) beschreiben. Das Signal besteht aus  $N$  Stufen, welche sich durch die Intervalle  $A_s$  und die Amplituden  $d_s$  beschreiben lassen.

$$u(k) = \sum_{s=1}^N d_s \chi_{A_s}(k) \quad (4.11)$$

Die Amplituden sind auf  $d_s \in [u_{\min}, u_{\max}]$  beschränkt.  $\chi_{A_s}$  ist die Indikatorfunktion der Amplitudenmenge  $A$ . Sie dient dazu die Amplituden auf ihre Teilbereiche  $A_s$  einzuschränken. Sie ist definiert nach Gl. (4.12)

$$\chi_{A_s}(k) = \begin{cases} 1 & \text{falls } k \in A_s \\ 0 & \text{falls } k \notin A_s \end{cases} \quad (4.12)$$

Dabei ist der Teilbereich  $A_s$  definiert durch Gl. (4.13) mit der Abtastzeit  $t_s$ . Wobei  $T_{h,s}$  die Zeiten sind, für welche der Sprung  $s$  des Signals  $u$  konstant gehalten wird.

$$A_s = \left\{ \frac{1}{t_s} \sum_{i=1}^{s-1} T_{h,i} + 1, \dots, \frac{1}{t_s} \sum_{i=1}^s T_{h,i} \right\} \quad (4.13)$$

Das APRBS lässt sich vollständig durch die Haltezeiten  $T_{h,s}$  und die Amplituden  $d_s$  beschreiben. Es ist notwendig eine hinreichend große Haltezeit  $T_{h,\min} \leq T_{h,s} \forall s$  zu verwenden, um dem System die notwendige Zeit zu geben sich einzuschwingen[TAN01]. Ist dies nicht der Fall, werden nur Bereiche  $y \approx (u_{\max} - u_{\min})/2$  abgedeckt und das Stationärverhalten des Systems kann nicht genau durch das Modell beschrieben werden [DEFL11].

Um die minimale Haltezeit  $T_{h,\min}$  für das APRBS zu bestimmen wurde ein Vorversuch durchgeführt. Hierfür wurde die Sprungantwort des Auslegerzylinders für den einen Sprung des Joysticksignals von 0 ‰ auf 800 ‰ untersucht. Dies entspricht dem maximalen Eingangssignal, welches im Kapitel 4.1.1 näher diskutiert wurde. Die Sprungantwort des Auslegerzylinders ist in der Abb. 4.8 dargestellt. Darin wird das Joysticksignal nur skaliert abgebildet.

Die blaue Linie zeigt in der Abb. 4.8 den Geschwindigkeitsverlauf des Auslegerzylinders. Es ist zu erkennen, dass der Ausleger zwischen dem Startzeitpunkt  $T_1 = 1,19$  s bis zum Erreichen des stationären Wertes zum Zeitpunkt  $T_2 = 2,38$  s eine Zeit von 1,2 s benötigt. Daher kann als minimale Haltezeit  $T_{h,\min} = 1,2$  s definiert werden.

Neben der minimalen Haltezeit ist bei der Applikation des APRBS auch notwendig, eine maximale Haltezeit  $T_{h,\max}$  zu definieren. Es gibt wie in dem Kapitel 4.1.1 gezeigt eine kontextbezogene Arbeitsraumbegrenzung und dadurch wird die maximale Haltezeit bestimmt. Die Haltezeit ergibt sich aus der benötigten Zeit den Arbeitsraum vollständig abzufahren. Für die angenommene Arbeitsraumbegrenzung benötigt der TCP bei einer reinen Bewegung des Auslegerzylinders etwa 3 s. Daher gilt für die Haltezeiten in Gleichung Gl. (4.13) :  $1,2 \text{ s} \leq T_{h,s} \leq 3 \text{ s} \quad \forall s$ .




Abbildung 4.8: Sprungantwort Auslegerzylinder

### 4.2.3 Sprunganregung

Die Sprunganregung ähnelt der APRBS, jedoch werden bei diesem Signal die Amplituden über den ganzen Arbeitsbereich konstant gehalten. Dieses statische Signal besitzt daher wenig dynamische Anteile. Aus diesem Grund ist zu erwarten, dass das Model die statischen Beziehungen gut erlernen kann. Im Vergleich zu den APRBS und dem Chirp hat das Sprungsignal keine gute Abbildung der Dynamik des Systems. Das Signal lässt sich durch die Gl. (4.14) beschreiben.

$$u(k) = \sum_{s=1}^N d_s \chi_{A_s}(k) \quad (4.14)$$

Die Amplituden  $d_s$  werden schrittweise in dem Arbeitsbereich  $[u_{min}, u_{max}]$  erhöht. Die Amplitude wird durch die Indikatorfunktion  $\chi_{A_s}$  auf Arbeitsbereich begrenzt.

$$\chi_{A_s}(k) = \begin{cases} 1 & \text{falls } k \in A_s \wedge z_{min} < z < z_{max} \\ 0 & \text{falls } k \notin A_s \vee z_{min} > z > z_{max} \end{cases} \quad (4.15)$$

## 4.3 Datennachbearbeitung

Die Datennachbereitung stellt einen wichtigen Teil bei der Aufnahme von Daten für die Modellierung dar. Die Versuchsdaten werden mit DSpace Controlldesk erfasst und als Matrizen abgespeichert. Die Daten werden dabei mit der gewählten Abtastrate von  $T_s = 0,01 \text{ s}$  digital abgetastet. Die gewonnenen Daten können nicht direkt für die Modellbildung eingesetzt werden, sondern müssen offline Nachbearbeitet werden. Die Messwerte werden zunächst auf verschiedene Faktoren wie Rauschen, Ausreißer und fehlende Daten überprüft [VYAS19]. Anschließend ist es notwendig diese Störungen zu beseitigen, um spätere Probleme mit der Modellierung (mit Hilfe von datenbasierten Methoden) zu reduzieren [LJUN99]. Nachfolgend werden die eingesetzten Methoden zur Kompensation der Störungen dargestellt.

### 4.3.1 Ausreißer

Bei der Aufnahme der Messungen kann es zu Ausreißern durch Störungen der Messeinrichtung kommen. Bei diesen Messpunkten handelt es sich um Punkte welche nicht in den Verlauf des Systemverhaltens passen. Sie erscheinen in dem Signalverlauf meist als Sprünge. Werden diese Punkte nicht von dem Datensatz entfernt, kann dies zu negativen Auswirkungen auf das geschätzte Modell haben, da es zu großen Abweichungen zwischen dem wahren Wert und dem gemessenen Wert kommt [WANG11]. Dieser Fehler führt zu einem Anstieg der Fehlerfunktion bei dem Training des Modells (siehe Gl. (3.3)), wodurch es zu einer Überanpassung der Parameter kommen kann [ZHU18].

Die Störungen können entweder von dem Datensatz entfernt oder mit Hilfe der Interpolation ersetzt werden. Das Entfernen eines Datenpunktes kann nur für statische Modelle (ohne zeitverzögerte Eingänge und Ausgänge) genutzt werden, da es sonst zum Anstieg der Transienten kommt [JELA12]. Treten diese Ausreißer für mehrere Zeitschritte auf ist es von Vorteil die Messung zu wiederholen [PEAR02].

Da mit den gesammelten Daten auch Modelle mit externer Dynamik erstellt werden sollen, ist es erforderlich die Störstellen durch interpolierte Werte zu ersetzen. Hierfür werden zunächst die Ausreißer gesucht und anschließend mit einer definierten Methode ersetzt. Die Abb. 4.9 zeigt einen Ausschnitt aus dem Druckverlauf des Pleueldrucks von dem Stielzylinder. Es ist zu erkennen, dass die Messfehler nur für einen Zeitschritt auftreten, wodurch eine lineare Interpolation zwischen den zwei Datenpunkten eine hinreichend genaue Methode darstellt [PEAR02]. Für die Identifikation wird der gleitende Median eingesetzt. Bei dieser Methode wird der Median über einen definierten Zeithorizont  $n_F$  gebildet und mit dem aktuellen Messwert verglichen. Ist der Wert größer als drei Median Absolute Deviation (MAD) von dem Median über einem definierten Zeithorizont, so wird der Messwert als Ausreißer identifiziert. Die MAD wird durch die Gl. (4.16)

berechnet. Dabei ist  $F$  Datenvektor bestehend aus  $n_F$  Messwerten.

$$MAD = \text{median}(|F_i - \text{median}(F)|) \quad (4.16)$$

Die Abb. 4.9 zeigt den Einsatz dieser Methode anhand des Druckverlaufes der Pumpe. In der Darstellung wird der Druck über der Zeit dargestellt. Die orangefarbenen Punkte stellen die interpolierten Werte dar und die blaue Linie den wahren Signalverlauf.




Abbildung 4.9: Behebung von Ausreißern

Es ist zu erkennen, dass es einen Ausreißer in dem Signalverlauf gibt. Dieser wird mit Hilfe der dargestellten Methode detektiert und durch eine lineare Interpolation ersetzt. Betrachtet man den interpolierten Wert so zeigt die Abb. 4.9, dass der Interpolierte Werte eine gute Approximation des Druckverlaufs darstellt.

### 4.3.2 Filterung der Trainingsdaten

Die Filterung der Trainingsdaten hat die Aufgabe hochfrequente Störungen, welche oberhalb der interessierenden Frequenzen der Systemdynamik liegen, herauszufiltern [LJUN99]. Die Abb. 4.10 zeigt das Blockschaltbild der Filterung und der Strecke.




Abbildung 4.10: Grundstruktur für die Filterung der Daten

An dem Bagger werden eine Reihe von Drücken  $\tilde{p}$  gemessen. Hierfür sind Sensoren zur Messung des LS-Drucks, Pumpendrucks und den Drücken an beiden Seiten der einzelnen Zylinder vorhanden. Die Drücke werden dem Filter  $G_F^p$  gefiltert. Neben den Drücken werden auch die Positionen der einzelnen Zylinder mit Hilfe von Seilzugsensoren  $\tilde{s}$  gemessen. Für die Modellierung ist es notwendig die Geschwindigkeit der einzelnen Zylinder zu kennen, daher muss die Geschwindigkeit mit Hilfe des Filters  $G_F^s$  bestimmt werden.

### Filterung der Drücke

Die gemessenen Drücke an dem Bagger sind nicht frei von Störungen. Daher ist es erforderlich einen Filter zu entwickeln um die Störungen herauszufiltern. Der Filter muss direkt online auf dem Versuchsträger eingesetzt werden können. Daher ist auf eine komplexe Struktur möglichst zu verzichten. Zur Analyse der auftretenden Spektren in den Drucksignalen wird eine Fourier-Transformation eines Drucksignals durchgeführt. Die Abb. 4.11 zeigt die Ergebnisse der Fourier-Transformation für das LS-Drucksignal.




Abbildung 4.11: Fourier-Transformation des LS-Drucksignals

Die Abb. 4.11 zeigt den normierten Betrag des Spektrums (y-Achse) über den Frequenzen (x-Achse). Es ist zu erkennen, dass ab etwa 6 Hz keine nennenswerten Spektralanteile auftreten. Die Fourier-Transformation lässt drauf schließen, dass ein einfacherer Filter erster Ordnung ausreicht für die Filterung der Drücke. Als Zeitkonstante kann für die Übertragungsfunktion  $T_F^p = 0,015$  angenommen werden.

Neben der Reduzierung der Störungen wird durch den Filter auch die hochfrequente Dynamik des Signals reduziert. Das hydraulische System ist im Vergleich zu dem mechanischen System dynamischer. In dem Modell soll die Druckinformationen primär zur Abbildung des Lastzustandes dienen, daher ist es sinnvoll die Dynamik des hydraulischen Systems durch den Filter  $G_F^p$  zu reduzieren.

### Bestimmung der Geschwindigkeit und Beschleunigung

Die Geschwindigkeit der hydraulischen Zylinder kann nicht direkt gemessen werden. Daher muss die Geschwindigkeit aus dem Positionssignal bestimmt werden. Die Position der Zylinder wird von Seilzugsensoren gemessen und mit Hilfe der numerischen Ableitung des Signals wird die Geschwindigkeit bestimmt. Eine Darstellung des abgeleiteten Messsignals ist in der Abb. 4.12 gezeigt.




Abbildung 4.12: Numerische Ableitung des ungefilterten Positionssignals

Es ist in der Abb. 4.12 zu sehen, dass das Signal starke Störungen aufzeigt. Diese kommen zum einen von dem Messrauschen des Seilzugsensors und zum anderen treten Quantisierungsfehler bei der Analog-Digital-Umwandlung auf. Das Messsignal wird mit Hilfe von einem CAN versendet, welches außerdem zu den Fehlern beitragen kann. Das Signal wie in der Abb. 4.12 gezeigt, kann nicht für das Training des Neuronalen Netzes verwendet werden, da die Störungen zu groß sind.

Die Signalqualität ist so schlecht, da durch die numerische Ableitung das Rauschen weiter verstärkt wird. Um eine Verbesserung der Signalqualität zu erreichen, wird nachfolgend ein Filter zur Berechnung der Geschwindigkeit entwickelt. Prinzipiell kann auch für die Bestimmung der gleiche Filter verwendet werden wie für die Druckfilterung, jedoch führt der Einsatz dieses Filter zu einer starken Phasenverschiebung des Signals. Bei der späteren Modellierung mit Neuronalen Netzen handelt es sich um einen Offline Identifikation (Modell wird nicht direkt während des Betriebs erstellt). Eine Offline-Identifikation bietet die Möglichkeit auch nichtkausale Filter zu verwenden [BOHN16]. Dadurch kann die Phasenverschiebung des gefilterten Signals kompensiert werden und Filter höherer Ordnung genutzt werden.

In [Mat19] wird der Einsatz eines ableitenden FIR-Filters vorgeschlagen. Dieser Filter hat die Eigenschaft das Rauschen bei der Ableitung nicht weiter zu verstärken. FIR-Filter sind stets stabil und werden eingesetzt, wenn ein linearer Phasengang im Durchlassbereich erwünscht ist [MEYE14]. Die Abb. 4.13 zeigt den Vergleich zwischen dem empfohlenen FIR-Filter mit einem Filter erster Ordnung.






Abbildung 4.13: Vergleich FIR- und PT1-Filter

Wie in der Abb. 4.13 zu erkennen, stellt die Filterung mit dem FIR-Filter eine bessere Approximation des Signalverlaufs dar. Die Darstellung verdeutlicht die auftretende Phasenverschiebung des PT1-Filters. Diese Verschiebung kann wie in der Abb. 4.13 zu erkennen mit dem FIR-Filter kompensiert werden.

## 4.4 Vergleich der Messreihen

Die in dem Abschnitt 4.2 vorgestellten Anregungssignale werden zur Evaluierung auf der Auslegerachse des Baggers appliziert. Die Abb. 4.14 zeigt die drei unterschiedlichen untersuchten Signale.




Abbildung 4.14: Applizierte Signale zur Datengenerierung

Die Abb. 4.14a zeigt das verwendete Chirp Signal. Es ist der Darstellung zu entnehmen, dass das Signal 200 s lange ist. Die Startfrequenz beträgt 3 Hz und die Endfrequenz 0,25 Hz. Die APRBS in der Abb. 4.14c besteht aus 200 unterschiedlichen Amplituden mit unterschiedlichen Haltezeiten (vgl. Abschnitt 4.2.2). Wie in der Abb. 4.14c zu sehen, beträgt die Messzeit etwa 500 s. In der Abb. 4.14b ist das Sprungsignal dargestellt. Die Sprünge werden wie zu erkennen zehn mal schrittweise erhöht. Daraus ergibt sich eine Messzeit für das Sprungsignal von etwa 520 s.

#### 4.4.1 Eingangs Ausgangskorrelation

Die Korrelation zwischen den zuvor gezeigten Joysticksignalen und den gemessenen Größen wird mit einem Streudiagramm untersucht. Aufgrund der geringen Abtastzeit können allerdings nicht alle gemessenen Punkte in einem Streudiagramm dargestellt werden. Die Messwerte werden daher in sogenannte Bins zusammengefasst. Es handelt sich dabei um eine Diskretisierung des Datenraums durch Rechtecke (Bins), welche je nach Datendichte eine andere Farbe haben. Daraus ist zu erkennen in welchen Bereichen eine hohe Dichte an Messwerten vorliegt. Für die Darstellung des Streudiagramms wird die Skala in der Abb. 4.15 verwendet.



Abbildung 4.15: Legende für die Streudiagramme

Die Abb. 4.15 zeigt den Farbverlauf der Legende für die Bins von einer geringen bis zu einer hohen Datendichte an Messpunkten. Es ist in der Abb. 4.15 zu sehen, dass eine niedrige Dichte an Messdaten dunkel blau dargestellt wird. Bins in denen viele Messwerte liegen werden in Gelb visualisiert.

#### Geschwindigkeit

Zunächst wird die Verteilung der Geschwindigkeit mit Hilfe des Streudiagramms untersucht. Die Abb. 4.16 zeigt die Streudiagramme für die drei unterschiedlichen Anregungssignale. In den Diagrammen wird die Geschwindigkeit des Auslegerzylinders auf der y-Achse über dem Joysticksignal des Auslegerzylinders auf der x-Achse dargestellt. Die Streudiagramme zeigen jeweils eine Messung mit einer festen Stielposition von 0 %. Dementsprechend bleibt die Last annähernd konstant und es wird nur ein Lastzustand abgebildet.




Abbildung 4.16: Korrelation der Geschwindigkeit mit dem Joysticksignal

Vergleicht man die drei Streudiagramme, so fällt eine unterschiedliche Abdeckung des Datenraums auf. Die Anregung durch das Chirp Signal zeigt in der Abb. 4.16a aufgrund der harmonischen Bewegung eine geringe Streuung der Messwerte. Es ist zu sehen, dass die gelben Bins eine Hysterese ausbilden.

Die Anregung mit den Sprüngen hingegen besteht zum großen Teil aus stationären Geschwindigkeiten. Dadurch ist auch in der Abb. 4.16b die stationäre Kennlinie zu erkennen. Diese Kennlinie spiegelt die applizierte Kennlinie aus der Bagger Inbetriebnahme wider. Aufgrund der großen Anzahl an Bereichen mit einem konstanten Joysticksignal ist zu erwarten, dass das daraus erzeugte Modell auch eine gute Güte in dem stationären Bereich liefert.

Das APRBS führt wie in der Abb. 4.16c zu sehen zu einer Kombination der beiden Signale. Das Streudiagramm hat eine breite Streuung der Messwerte und zugleich eine klare Ausprägung um die stationäre Kennlinie. Durch diese breite Streuung stehen dem datenbasierten Modell bereits viele mögliche Kombinationen an Messwerten zur Verfügung. Es ist dadurch möglich eine bessere Performance über den ganzen Arbeitsbereich zu erzielen.

### Druckdifferenz über der Blende

Die Druckdifferenz zwischen dem Pumpendruck  $p_{pmp}$  und dem LS-Druck  $p_{LS}$  hat wie in Gl. (2.2) zu sehen, einen Einfluss auf den Volumenstrom des Ventils. Bei konstantem Joysticksignal und dadurch konstanter Blendenöffnungsfläche tritt eine Geschwindigkeitsänderung auf, falls  $\Delta p_{pmp,LS}$  sich ändert. Die Druckdifferenz ändert sich in Abhängigkeit von der Last. Die Druckdifferenz  $\Delta p_{pmp,LS}$  spiegelt daher den Lastzustand des Systems wieder. Es ist daher notwendig auch die Verteilungen des Druckes gegenüber dem Joysticksignal zu analysieren.




Abbildung 4.17: Korrelation der Blendendruckdifferenz mit dem Joysticksignal

Die Abb. 4.17 zeigt die Druckstreudiagramme für die drei unterschiedlichen Anregungssignale. In der Darstellung ist die Druckdifferenz auf der Ordinate und das Joysticksignal auf Abszisse aufge-

tragen.

Bei dem Chirp Signal (siehe Abb. 4.17a) fällt auf, dass es eine geringe Streuung der Messwerte gibt. Die gelben Bins zeigen, dass es eine dichte Anhäufung an Messwerten gibt. Es fällt auf, dass es zu Bereichen ohne Messwerte in der Abdeckung gibt. Treten nun Druckdifferenzen genau in diesen Bereichen auf so muss das datenbasierte Modell interpolieren, wodurch es zu einer geringen Modellgüte kommen kann. Vergleicht man Abb. 4.17a mit Abb. 4.17b (Sprunganregung) so ist zu erkennen, dass auch hier sich die Messwerte konzentriert sind. Dies führt bei der Modellierung zu dem gleichen erläuterten Problem wie bei Anregung mit dem Chirp Signal.

Das APRBS (Abb. 4.17c) besitzt im Vergleich zu der Sprunganregung und der Anregung mit einem Chirp Signal eine breite Streuung der Druckdifferenz. Dadurch ist bereits in den generierten Daten eine größere Vielfalt an Lastzuständen abgedeckt. Durch diese Streuung ist zu erwarten, dass das erzeugte Modell eine gute Abhängigkeit von den Lastzuständen besitzt.

### Druckdifferenz im Zylinder

Neben der Druckdifferenz der Blende spielt die Druckdifferenz zwischen dem Kopf-  $p_{Hd}$  und der Kolbenseite  $p_{Rd}$  eine wichtige Rolle bei der Beschreibung der Dynamik des Kolbens. Die Druckdifferenz gibt Aufschluss über die auf den Zylinder wirkende Last. Der LS-Druck  $p_{LS}$  kann während des Betriebs zwischen den Zylindern wechseln. Die Abb. 4.18 zeigt die Verteilungen der drei Anregungssignale in einem zweidimensionalen Streudiagramm.




Abbildung 4.18: Korrelation der Zylinderdruckdifferenz mit dem Joysticksignal

In der Abb. 4.18a ist das Streudiagramm für die Anregung des Stielzylinders mit dem Chirp Signal zu sehen. Es ist zu erkennen, dass es eine geringe Streuung der Messwerte gibt. Besonders in dem Bereich mit negativen Joystickwerten zeigen sich Bereiche, in denen keine Daten vorliegen. Es ist eine dominante Verteilung der Messwerte zu erkennen. Das Streudiagramm der Sprunganregung (Abb. 4.18b) zeigt ein ähnliches Bild. Die Streuung der Messwerte ist gering. Besonders im positiven

Bereich zeigt sich eine dominante Anhäufung der Daten entlang einer Geraden.

Im Gegensatz zu diesen zwei Anregungen besitzt das Streudiagramm des APRBS-Signals eine breite Streuung der Messdaten. Die Messpunkte der Druckdifferenz liegen zwischen 0 bar und 250 bar. Hinsichtlich der Streuung der Messwerte und dem dementsprechend hohen Informationsgehalt zeigt das APRBS das beste Ergebnis.

#### 4.4.2 Verteilungen

Die Messungen werden mit Hilfe von Histogrammen wie in [DOHE97] vorgestellt analysiert, um eine erste Aussage über die Verteilung der Daten im Arbeitsbereich zu geben. Hierfür wird der Arbeitsbereich in kleine Teilbereiche unterteilt und anschließend die Anzahl der Messwerte in dem Bereich gezählt. Anschließend wird die Häufigkeit über dem Arbeitsbereich dargestellt. Im Idealfall ist der Arbeitsbereich gleichmäßig abgedeckt [DOHE97].

Die Abb. 4.19 zeigt die Histogramme für die drei Anregungssignale. Die Anzahl der Messwerte wird auf der y-Achse logarithmisch dargestellt.




Abbildung 4.19: Verteilungen der Joysticksignale

Das Chirpsignal (siehe Abb. 4.19a) hat aufgrund der gleichmäßigen Anregung keine stationären Bereiche. Dadurch kommt es zu einer gleichmäßigen Verteilung. Die Anzahl der Messwerte in allen Klassen liegt zwischen  $10^2$  und  $10^3$ . Aus diesem Grund stehen dem datenbasierten Modell über dem gesamten Anregungsbereich gleich viele Datenpunkte zur Verfügung, was eine Überanpassung verhindert [BOHN16].

In der Abb. 4.19b sind die Verteilungen der Sprunganregung zu erkennen. Es fällt auf, dass die Anzahl der Messwerte für kleine Joysticksignale zunimmt. Diese Verteilung ist damit zu erklären, dass der TCP bei kleinen Geschwindigkeiten länger benötigt um den gesamten Arbeitsbereich abzudecken. Die Anhäufung der Daten bei kleinen Joystickwerten kann zu einer Überanpassung an diesen Bereich führen.

Das APRBS-Signal (Abb. 4.19c) zeigt wie auch das Chirp-Signal eine gleichmäßige Abdeckung des Eingangsraums. Im Gegensatz zu der Senke bei Chirp (Abb. 4.19c) zeigt die APRBS eine Erhöhung bei mittleren Joystickwerten auf. Aus Sicht der Datenverteilung eignet sich das Chirp und APRBS Signal am besten für die datenbasierte Modellierung.

## 5 Modellbildung

Obwohl die physikalisch motivierten Modelle auf soliden Grundlagen der Physik und des Denkens basieren, gibt es bei dem Erreichen eines hinreichend genauen Modells Probleme [BOHN16]. Da bei dieser Modellbildung meist Annahmen (wie z. B. reibungslose Verbindungen oder vernachlässigbare Kräfte bei niedrigen Geschwindigkeiten) getroffen werden welche nicht vollständig erfüllt sind [VIDO16]. Weiterhin stellt die präzise Abbildung von nichtlinearen Effekten wie Reibung oder Dämpfungen eine große Herausforderung dar [CHIN12]. Werden diese Effekte abgebildet so kommt es häufig vor, dass das daraus resultierende Modell eine zu hohe Rechenkapazität benötigt um in einem Regler eingesetzt zu werden [KELA14]. Es ist daher notwendig die komplexen Modelle zu vereinfachen um diese in einem modellbasierten Regler einsetzen zu können [CAND12]. Die Modelle bilden dann meist nur noch die wesentlichen physikalischen Effekte des Systems ab, wodurch es zu einem Informationsverlust kommt [KELA14].

Methoden des maschinellen Lernens besitzen eine hohe Flexibilität und Anpassungsfähigkeit und können daher auch diese genannten Herausforderungen der theoretischen Modellierung lösen [BRAM18]. Für diese Modelle ist es wie in dem vorherigen Kapitel gezeigt zunächst notwendig Daten zu sammeln. Mit diesen Daten kann das datenbasierte Modell erstellt (trainiert) werden. Ein großer Vorteil dieses Ansatzes ist die Übertragbarkeit. Die in dem Kapitel 4 gezeigten Strategien lassen sich auf andere Bagger übertragen. Dadurch ist der Aufwand für die Datengenerierung und Modellerstellung gering im Vergleich zu nicht datenbasierten Methoden. Um eine Übertragbarkeit des Modells zu gewährleisten ist es notwendig eine Modellstruktur zu wählen, welche sich auch auf andere Bagger übertragen lässt. Besonderer Fokus bei der Entwicklung liegt hier bei der Auswahl der notwendigen Regressoren für das Modell, da die gewählten Regressoren später entscheiden, welche Sensoren an dem Fahrzeug notwendig sind. In Bezug auf den Serieneinsatz von solchen Modellen spielt die Anzahl der Sensoren bei der Entwicklung einen entscheidenden Kostenfaktor. Aus diesem Grund wird in diesem Kapitel näher untersucht, welche Regressoren für die Modellierung notwendig sind.

### 5.1 Inverses Streckenmodell

Mit Hilfe der im vorherigen Kapitel dargestellten Daten, soll ein Modell des inversen Streckenverhaltens erstellt werden. Das Modell wird als invers bezeichnet, weil von der Ausgangsgröße der

Strecke auf die dafür notwendige Eingangsgröße geschlossen werden soll. Das Problem lässt sich nach Gleichung Gl. (5.1) formulieren. Für die Approximation der Funktion  $g()$  kommt ein neuronales Netz zum Einsatz. Die Regressoren  $\phi$  für das Modell können variieren. Im späteren modellbasierten Regler soll das Modell von einer Sollgeschwindigkeit auf einen dafür notwendiges Joysticksignal schließen. Daher ist als Regressor mindestens die Geschwindigkeit  $\dot{s}$  notwendig, um auf das dafür notwendige Joysticksignal  $Jystk$  zu schließen.

$$Jystk(k) = g(\underline{\phi}_k, \underline{w}) = g([\dot{s}(k), s(k), p(k) \dots], \underline{w}) \quad (5.1)$$

Zur Anpassung der Gewichte  $\underline{w}$  wird die Gl. (5.2) verwendet. Dabei handelt es sich um ein Optimierungsproblem welches iterativ gelöst werden muss, um den Fehler der Vorhersage zu minimieren.

$$Jystk(k) = g(\underline{\phi}_k, \underline{w}) = g([\dot{s}(k), s(k), p(k) \dots], \underline{w}) \quad (5.2)$$

Für die Lösung dieses Optimierungsproblems kommt die Struktur aus der Abb. 5.1 zum Einsatz. Dabei kommen zur Filterung der gemessenen Größen  $(\tilde{s}, \tilde{p})$  die im vorherigen Kapitel dargestellten Filter zum Einsatz.

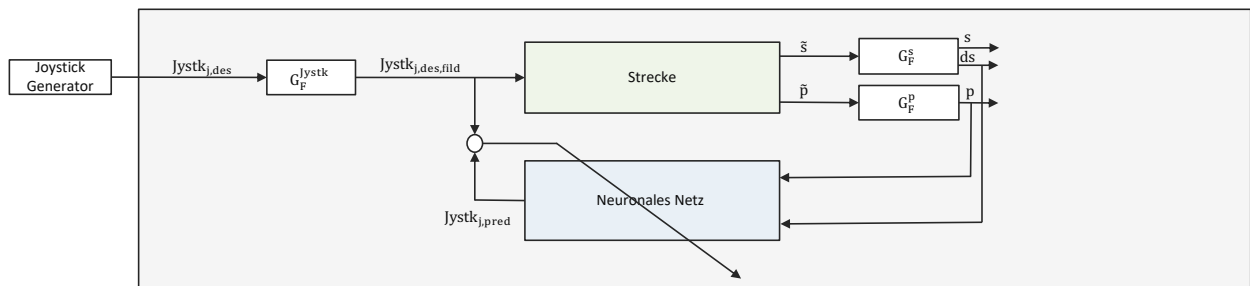


Abbildung 5.1: Training des Neuronalen Netzes

Es ist in der Abb. 5.1 zu erkennen, dass die Gewichte des neuronalen Netzes mit dem Fehler zwischen den vorhergesagten  $Jystk_{pred}$  und dem Systemeingang  $Jystk_{des,fild}$  angepasst werden. Als Eingänge des Neuronalen Netzes werden die gemessenen Systemausgänge und Zustände der Strecke verwendet. Wie bereits in dem vorherigen Kapitel dargestellt, beschränkt sich die Modellierung zunächst nur auf den Auslegerzylinder. Das erzeugte Modell ist daher auch nur für einen Zylinder des Baggers gültig. Wie in der Belegung der Joysticks von Baggern (siehe Abb. 2.8) zu sehen, wird jeder Raumrichtung auf dem Joystick ein Zylinder zugeordnet. Daher ist es möglich für jeden Zylinder ein einzelnes Netz zu trainieren. Das hat den Vorteil, dass die Modelle besser an das zu lösende Optimierungsproblem angepasst werden können. Die trainierten Netze werden anschließend in einem separaten Geschwindigkeitsregler für jeden Zylinder verwendet.



## 5.2 Abbildung der Dynamik

Die Dynamik des Systems kann bei der Verwendung von Neuronalen Netzen durch interne oder externe Verfahren abgebildet werden. Bei den internen Verfahren gibt es eine Rückführung innerhalb des Neuronalen Netz (NN). Beispiel hierfür sind Long-Short-Time-Memory (LSTM) Netzwerke. Diese haben im Gegensatz zu Standard Neuronalen Netzen rekurrente Verbindungen. Rekurrente Netz haben die Eigenschaft Informationen aus der Vergangenheit zu speichern [RUEC17]. Bei den Verfahren mit externer Dynamik wird ein statisches Neuronales Netz mit einem Speicher der vergangen Eingangs- oder Ausgangsgröße kombiniert. Die Implementierung einer externen Dynamik hat den Vorteil, dass sie eine geringere Rechenleistung zur Auswertung des Modells benötigt als Verfahren mit interner Dynamik [DEFL11]. Das macht es möglich diese Netze auch auf einem Steuergerät in Echtzeit zu verwenden. Diese Arbeit beschränkt sich daher auf Netze mit externer Dynamik.

Die Methoden mit externer Dynamik lassen sich in die drei Modellkonfigurationen (Tab. 5.1) einteilen. Die Regressoren des Neuronalen Netzes können neben den gemessenen Werten  $\underline{\mathbf{U}} \in \mathbb{R}^{N_u \times K}$  und  $\underline{\mathbf{Y}} \in \mathbb{R}^{N_y \times K}$  auch simulierte Werte  $\hat{\underline{\mathbf{Y}}} \in \mathbb{R}^{N_y \times K}$  enthalten. Bei der Notation wird nachfolgend  $\underline{\mathbf{U}}$  als Eingang des Neuronalen Netzes und  $\hat{\underline{\mathbf{Y}}}$  als Ausgang des Neuronalen Netzes verwendet. Da es sich bei dem zu identifizierenden Problemen um eine direkte Beschreibung des inversen Streckenverhaltens handelt entspricht der Eingang des Modells dem Ausgang der Strecke.

Tabelle 5.1: Überblick der Modellstrukturen

| Bezeichnung  | Regressor  |
|--|--|
| NFIR (Nonlinear Finite Impulse Response)             | $\underline{\mathbf{U}}$                               |
| NARX (Nonlinear AutoRegressive with eXogenous input) | $\underline{\mathbf{U}}, \underline{\mathbf{Y}}$       |
| NOE (Nonlinear Output Error)                         | $\underline{\mathbf{U}}, \hat{\underline{\mathbf{Y}}}$ |

Wie in der Tab. 5.1 zu erkennen, verwenden die NFIR-Modelle als Regressor nur die Modelleingänge (sie werden als Vektor  $\underline{\mathbf{U}}$  zusammengefasst). In dem vorgestellten inversen Modell entsprechen diese den Ausgängen und Zuständen des Baggers (Drücke und Positionen). Bei den NARX-Modellen wird der gemessene Ausgang  $\underline{\mathbf{Y}}$  (im Fall der inversen Modellierung ; das Joysticksignal) als zusätzlicher Regressor verwendet. NARX-Modelle haben den Nachteil, dass sie nur einen Zeitschritt vorhersagen können. Wird die Vorhersage über mehrere Zeitschritte benötigt, müssen NOE-Modelle eingesetzt werden. Bei diesen Modellen wird der vorhergesagten Netzausgangs  $\hat{\underline{\mathbf{Y}}}$  als zusätzlicher Eingang des Neuronalen Netzes verwendet. Die NOE-Modelle haben durch diese Rückführung des vorhergesagten Netzausgangs das Problem der Fehleraufsummierung. Dadurch kann das Modell instabil werden.

Die NARX-Modelle und die NOE-Modelle werden in dieser Arbeit nicht weiter untersucht, da das Modell später als Vorsteuerung in einem Geschwindigkeitsregler eingesetzt wird und das Joystick-

signal bei der Regelung nicht gemessen werden kann. Bei dem Einsatz in dem Regler wird nicht die gemessene Geschwindigkeit, sondern eine Sollgeschwindigkeit vorgegeben und die Drücke gemessen. Die Drücke können als Rückführung aufgefasst werden. Daher wird in der Arbeit ein NFIR-Modell verwendet. Diese weisen zwar ein Informationsdefizit gegenüber Modellen auf welche die Ausgangsgröße (Joystick) auch als Eingang nutzen, jedoch haben sie den Vorteil die Instabilität zu verhindern.

Die Dynamik in der NFIR-Modellstruktur kann mit Hilfe von Verzögerungsgliedern erzeugt werden [DEFL11]. Bei diesem Verfahren stehen dem Netzwerk zusätzlich die Messwerte für einen vergangenen Horizont zur Verfügung. Beispielsweise steht dem Netz nicht nur die aktuelle, sondern auch die letzten zwei Positionen des Zylinders zur Verfügung. Wie bereits im vorherigen Kapitel beschrieben, kann die Geschwindigkeit der Zylinder nicht direkt gemessen werden. Wird dem Modell nur die Positionen über einen gewissen Zeithorizont übergeben, so muss das Netz die Informationen über die Geschwindigkeit und Beschleunigung aus den Daten selbst extrahieren und die Komplexität des zu lösenden Problems kann steigen.

Eine Alternative stellt die externe Berechnung der zeitlichen Änderung der Signale dar. Bei diesem Verfahren werden die Geschwindigkeiten und Beschleunigungswerte dem Modell übergeben. Diese Arbeit beschränkt sich auf die Abbildung der Dynamik mit der externen Berechnung von physikalischen Größen, um möglichst viele Informationen über das System in den Regressoren bereits vorzugeben. Die Abbildung der Dynamik des Modells lässt sich nach Abb. 5.2 darstellen.

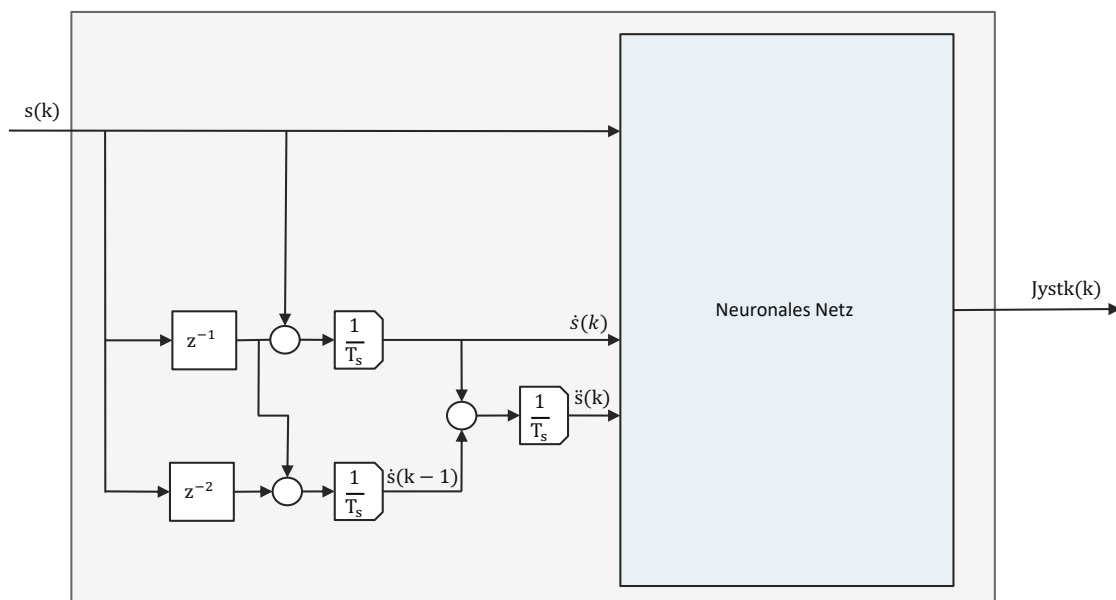


Abbildung 5.2: Externe Dynamik des Modells

In der Abb. 5.2 ist zu erkennen, dass dem Modell die Geschwindigkeit und die Beschleunigung des Zylinders zugeführt wird. Die Änderungen des Systems werden nicht direkt durch Verzöge-

rungsglieder umgesetzt sondern die Ableitungen der Signale betrachtet. Dieser Ansatz bietet den Vorteil, dass die Modelle auch mit einer anderen Abtastzeit verwendet werden können. Wie in der Abb. 5.2 zu erkennen wird die Geschwindigkeit aus dem Positionssignal  $s$  bestimmt. Hierfür wird die Geschwindigkeit aus den diskret abgetasteten Positionswerten nach Gl. (5.3) bestimmt. In der Gleichung ist  $T_s$  die Abtastzeit.

$$\dot{s}(k) = \frac{s(k) - s(k-1)}{T_s} \quad (5.3)$$

Neben der Geschwindigkeit wird auch die Änderung der Geschwindigkeit untersucht. Die Beschleunigung kann durch die Approximation der zweiten Ableitung des Positionssignals errechnet werden. Hierfür wird die Beschleunigung nach Gl. (5.4) bestimmt.

$$\ddot{s}(k) = \frac{\dot{s}(k) - \dot{s}(k-1)}{T_s} = \frac{s(k) - 2 \cdot s(k-1) + s(k-2)}{2 \cdot T_s} \quad (5.4)$$

## 5.3 Hyperparameter

Um bei dem Training ein möglichst gutes Modell zu erzeugen ist es notwendig gewisse Modellparameter (Hyperparameter) zu optimieren. Die Qualität des Modells hängt von der Wahl der Hyperparameter ab [VYAS19]. So kann ein Modell für das Problem gut geeignet sein, jedoch durch eine schlechte Wahl der Hyperparameter eine schlechte Modellperformance liefern [JIMÉ07]. Damit dies verhindert wird, wird für die Optimierung der Hyperparameter das in dem Kapitel 3.4.3 vorgestellte Verfahren der modellbasierte Bayesian Optimierung verwendet. Für diese Optimierung müssen gewisse minimale und maximale Grenzen für Hyperparameter (numerische Größen) definiert werden. Für nicht numerische Parameter ist es erforderlich Kategorien zu definieren, aus denen während der Optimierung gewählt werden kann. Nachfolgend wird auf die möglichen Hyperparameter und deren Auswirkungen auf das Neuronale Netz eingegangen.

### 5.3.1 Anzahl an Schichten

Die Möglichkeit eines Netzwerkes komplexe Funktionen abbilden zu können wird durch die Anzahl an Schichten beschränkt [GOOD16]. In der Theorie kann ein Netzwerk mit einer verdeckten Schicht, mit einer ausreichenden Anzahl an Neuronen, jede beliebige Funktion abbilden [KAAS96]. Durch die Zunahme der Schichten erhöht sich meist auch die Anzahl der Neuronen im gesamten Netzwerk. Dadurch nimmt die Anzahl der Gewichte zu, wodurch die notwendige Rechenleistung steigt. Jede weitere Schicht erzeugt auch weitere Nebenminima der Fehlerfunktion, dadurch kann es zu Problemen bei der Konvergenz kommen [KRIE07]. Das Optimierungsverfahren kann dadurch

in einem Nebenminima enden. Bei einer zu hohen Anzahl an Schichten neigt das Netzwerk außerdem zu Überanpassung. Um die Nachteile von mehr als einer verdeckten Schicht zu umgehen, aber dennoch nichtlineare Funktionen approximieren zu können, werden in der Hyperparameteroptimierung nur maximal drei verdeckte Schichten erlaubt.

### 5.3.2 Neuronenanzahl

Die Anzahl der Neuronen in der Eingangsschicht wird durch die Dimension der Regressoren und die Anzahl der Neuronen in der Ausgangsschicht durch die Dimension des Ausgangsraums bestimmt. Lediglich die Anzahl der Neuronen in den verdeckten Schichten kann bei der Hyperparameteroptimierung angepasst werden. Die potenzielle Modellgüte steigt mit der Anzahl an Neuronen in der verdeckten Schicht [WEIG17]. Werden zu wenige Neuronen verwendet, besitzt das Netzwerk zu wenige Freiheitsgrade und dadurch wird die Modellgüte begrenzt. Dadurch können komplexe Funktionen nicht mehr abgebildet werden. Es ist jedoch zu beachten, dass die Rechengeschwindigkeit des Netzwerks proportional zu der Anzahl der Neuronen ist. Da das Modell später auf einem Steuergerät in Echtzeit laufen soll ist die Neuronenanzahl in der verdeckten Schicht zu begrenzen. Die Neuronenanzahl der verdeckten Schicht ist daher ein Kompromiss aus Berechnungsgeschwindigkeit einerseits und Modellgüte andererseits. Bei der Optimierung wird eine Anzahl an Neuronen zwischen 5 und 30 Neuronen in der verdeckten Schicht erlaubt.

### 5.3.3 Wahl der Aktivierungsfunktionen

Die Aktivierungsfunktionen bestimmen die Trainingsgeschwindigkeit und Performance des Netzwerkes. Netzwerke können nur nichtlineare Funktionen abbilden, wenn in einer Schicht eine nichtlineare Aktivierungsfunktion verwendet wird. In Kapitel 3.3.2 ist eine Übersicht der gängigsten Aktivierungsfunktionen gezeigt. Bei der Hyperparameteroptimierung stehen die gezeigten Aktivierungsfunktionen zur Auswahl. Lediglich in der Ausgabeschicht wird die lineare Aktivierungsfunktion, wie bei Regressionsproblemen üblich, fest definiert [DURI17].

## 5.4 Strukturprüfung durch Auswahl signifikanter Regressoren

Bei den in dieser Arbeit eingesetzten Neuronalen Netzen ist im Voraus nicht bekannt, welche Regressoren für die Modellbeschreibung benötigt werden. Daher bietet die Strukturprüfung die Möglichkeit, alle notwendigen Regressoren für das Modell zu bestimmen [BOHN16]. Die Auswahl der signifikanten Regressoren ist notwendig, da diese über die später verbauten Sensoren entscheiden. Die Steigerung der Systemkosten soll durch die Implementierung Assistenzfunktionen möglichst gering gehalten werden.

Die möglichen Regressoren ergeben sich aus den zur Verfügung stehenden Messsignalen und Sensoren an dem Versuchsträger. Der Versuchsträger ist im Vergleich zu herkömmlichen Sensoren mit zusätzlichen Sensoren (zur Bestimmung der Position und Drücken der einzelnen Zylinder) ausgestattet. Aus den gemessenen Größen an dem Versuchsträger werden die signifikanten Regressoren ausgewählt, um eine Aussage über die notwendigen Sensoren treffen zu können. Nachfolgend wird die Anzahl der zur Verfügung stehenden Regressoren mit  $h_{max}$  bezeichnet. Ein heuristischer Ansatz zur Bestimmung der signifikanten Eingänge besteht darin, verschiedene Möglichkeiten für die Wahl der Regressoren durchzuprobieren und die so entstehenden Modelle zu vergleichen [BOHN16]. Daraus ergeben sich  $n_h$  Möglichkeiten aus der binomischen Formel (Gl. (5.5)), sofern alle möglichen Kombinationen ausprobiert werden.

$$n_h = \sum_{i=1}^{h_{max}} \binom{h_{max}}{i} = \sum_{i=1}^{h_{max}} \frac{h_{max}!}{i!(h_{max}-i)!} = 2^{h_{max}} - 1 \quad (5.5)$$

Die Tab. 5.2 zeigt die Auswahl der möglichen Regressoren für einen Zylinder. Wie zu sehen ist, beträgt die Anzahl an zu Verfügung stehenden Signalen sieben. Mit der Gl. (5.5) ergibt sich damit: 127 zu überprüfenden Kombinationen.

Tabelle 5.2: Gemessene Größen für einen Zylinder

| Zeichen    | Name                          |
|------------|-------------------------------|
| $s$        | Position des Zylinders        |
| $\dot{s}$  | Geschwindigkeit des Zylinders |
| $\ddot{s}$ | Beschleunigung des Zylinders  |
| $p_{Hd}$   | Kopfdruck des Zylinders       |
| $p_{Rd}$   | Pleuedruck des Zylinders      |
| $p_{Pmp}$  | Pumpendruck                   |
| $p_{Ls}$   | Lastdruck                     |

### 5.4.1 Kennzahlen der Modellgüte

Die unterschiedlichen Modelle bei der Auswahl der signifikanten Regressoren müssen untereinander verglichen werden. Zur Bewertung der Modellgüte kommen drei Kennzahlen zur Anwendung. Das Modell wird anhand des Root Mean Square Error (RMSE) bewertet. Der RMSE-Wert stellt eine Messgenauigkeit für die Vorhersage eines Modells dar. Der Vorteil im Gegensatz zu dem Bestimmtheitsmaß ist, dass das Ergebnis eine physikalische vergleichbare Einheit trägt. Der Wertebereich des RMSE ist größer als 0. Je geringer der RMSE-Wert, desto besser ist die Approximation des Modells. Der RMSE berechnet sich aus der Wurzel der Summe der quadratischen Fehler  $(\hat{y}_p - y_p)^2$  nach Gl. (5.6). Dabei ist  $\hat{y}_p$  der vorhergesagte und  $y_p$  der wahre Wert der Messreihe mit  $n_p$  Mess-

werten.

$$RMSE = \sqrt{\frac{\sum_{p=1}^{n_p} (\hat{y}_p - y_p)^2}{n_p}} \quad (5.6)$$

Weiterhin wird das Modell nach dem Bestimmtheitsmaß  $R^2$  bemessen. Das  $R^2$  ist ein Gütemaß der linearen Regression. Der Wertebereich des  $R^2$  liegt zwischen 0 und 1. Ist die Bestimmtheit 0 ist die Approximation des Modells ungenügend. Bei einem Wert von 1 spricht man von einem perfekten Modell. Der  $R^2$  ergibt sich aus Gl. (5.7), dabei ist  $\bar{y}$  der Mittelwert der Ausgangswerte.

$$R^2 = \frac{\sum_{p=1}^{n_p} (\hat{y}_p - \bar{y})^2}{\sum_{p=1}^{n_p} (y_p - \bar{y})^2} \quad (5.7)$$

Als weitere Kennzahl kommt Mean absolute error (MAE) zum Einsatz. Dieser ist ein gängiger Wert zur Beurteilung von Fehlern bei der Analyse von Zeitreihen [HYND06]. Der MAE kommt aus der Statistik und misst die vertikale Differenz zwischen zwei Variablen nach Gl. (5.8). Dabei ist  $\hat{y}_p$  der vorhergesagte und  $y_p$  der wahre Wert der Messreihe mit  $n_p$  Messwerten. Der MAE ergibt sich aus dem Durchschnitt der absoluten  $|\hat{y}_p - y_p|$ . Der Fehler benutzt die gleiche Einheit wie die Messgrößen. Dies hat den Vorteil, dass der Wert anschaulich ist. Jedoch ist zu beachten, dass dadurch eine Vergleichbarkeit mit Messgrößen auf anderen Skalen nicht möglich ist. Wie auch bei den RMSE steigt die Qualität der Vorhersage des Modells mit Abnahme des MAE.

$$MAE = \frac{\sum_{p=1}^{n_p} |\hat{y}_p - y_p|}{n_p} \quad (5.8)$$

### 5.4.2 Ergebnisse der Strukturprüfung

In der Strukturprüfung werden die unterschiedlichen Datensätze aus dem vorherigen Kapitel und unterschiedliche Kombinationen an Regressoren miteinander verglichen. Der Regressor muss mindestens die Geschwindigkeit des Zylinders enthalten sein. Wird jedoch nur das Eingangs- und Ausgangsverhalten verwendet so können die daraus resultierenden Modelle allgemein auch nur diesen Zusammenhang identifizieren. Durch Hinzunahme der internen messbaren Systemzustände ist es möglich bei der Identifikation auch die internen Strukturen des Systems zu beschreiben und dadurch die Modellqualität zu erhöhen [ISER10].

Die Abb. 5.3 zeigt die Strukturprüfung in Kombination mit einem Vergleich der unterschiedlichen Trainingsdatensätze. Die Kennzahlen werden auf einem Crossvalidierungsdatensatz bestimmt, welcher nicht Teil der Trainingsdaten ist. In der Abb. 5.3 werden die möglichen Druckinformationen in dem Regressor auf die Druckdifferenz zwischen dem Pumpen- und Lastdruck sowie Kopf- und Pleuedruck beschränkt. Die Druckdifferenzen haben in Voruntersuchungen bessere Ergebnisse erzielt, als die Einzeldrücke bei der datenbasierten Modellierung. In dem vorhanden theoretischen Modell werden nur die Druckdifferenzen verwendet. Die Druckdifferenz zwischen dem Pumpendruck  $p_{Pmp}$  und die des LS-Druck hat Einfluss auf den Volumenstrom des Zylinders (vgl. Gl. (2.2)).




Abbildung 5.3: Vergleich von der Regressoren

In der Abb. 5.3 werden die unterschiedlichen Trainingsdatensätze miteinander verglichen. Die Bewertung der Modelle erfolgt anhand des MAE und RMSE (siehe Abschnitt 5.4.1). In der Darstellung fällt auf, dass die Kennzahlen für das APRBS Signal die besten Ergebnisse liefern (niedrigere Werte). In der Abb. 5.3 ist zu erkennen, dass ein reiner Zusammenhang zwischen der Geschwindigkeit und dem Joysticksignal keine guten Ergebnisse auf dem Validierungsdatensatz liefert. Die Hinzunahme der Beschleunigung verbessert die Ergebnisse auf dem Validierungsdatensatz deutlich. Dadurch kann jedoch nicht die Lastabhängigkeit der Geschwindigkeit abgebildet werden. Diese Abhängigkeit ist entscheidend für die Robustheit des Modells gegenüber externen Kräften.

Die Hinzunahme der Druckdifferenzen ist notwendig um eine Adaption gegenüber externen Kräften zu ermöglichen. Das Einfügen der Druckdifferenz zwischen der Kopf-  $p_{Hd}$  und der Pleuelseite  $p_{Rd}$  spielt besonders bei Mehrachs-bewegungen eine Rolle, da der LS-Druck zwischen allen verbauten Zylindern wechseln kann (vgl. Abschnitt 2.3.2). Wie in Abb. 5.3 zu sehen, liefert das Beifügen beider Druckdifferenzen die besten Ergebnisse.

## 5.5 Ergebnisse

Die in dem vorherigen Abschnitt durchgeführte Analyse der Regressoren hat gezeigt, dass eine Abbildung von der Geschwindigkeit auf den Joystick nicht ausreichend ist. Es hat sich ergeben, dass das Neuronale Netz mit dem Eingang  $\phi \in \mathbb{N}^4$ , bestehend aus Zylindergeschwindigkeit  $\dot{s}$ , der Zylinderbeschleunigung  $\ddot{s}$ , der Druckdifferenz zwischen  $p_{Hd}$  und  $p_{Hl}$  sowie der Druckdifferenz zwischen  $p_{pmp}$  und  $p_{Ls}$ , die besten Ergebnisse bringt. Nachfolgend werden die Resultate der Modellierung für das in der Abb. 5.3 beste Ergebnis näher dargestellt.

### 5.5.1 Resultat der Optimierung

Bei allen trainierten Netzen aus der Regressorstudie wurde eine Hyperparamteroptimierung durchgeführt, da die optimalen Modellparameter auch abhängig von den Regressoren des Netzes sind. Die Abb. 5.4 zeigt den Verlauf der Optimierungskurve für das beste Ergebnis der Strukturprüfung.




Abbildung 5.4: Optimierungskurve des inversen datenbasierten Streckenmodells für den Auslegerzylinder

In der Abb. 5.4 wird auf der y-Achse der Mean Square Error (MSE) über den Epochen der Optimierung dargestellt. Die Anzahl an Optimierungsschritten wurde auf 50 begrenzt. In der Kurve ist zu sehen, dass der MSE mit steigender Anzahl an Iterationen tendenziell fällt. Es ist zu erkennen, dass nach 26 Epochen der beobachtete Fehler des trainierten Modells nicht weiter verbessert wurde. Der vorhergesagte Fehler ist auch nicht weiter gesunken. Es ist davon auszugehen, dass eine gute Optimierung der Hyperparameter stattgefunden hat. Die Ergebnisse der Hyperparameteroptimierung sind in der Tab. 5.3 zu entnehmen.



Tabelle 5.3: Ergebnisse der Hyperparameteroptimierung

| Hyperparameter                                 | Wert                 |
|--|----------------------|
| Anzahl an Neuronen in den verdeckten Schichten | 19                   |
| Anzahl an verdeckten Schichten                 | 2                    |
| Aktivierungsfunktionen                         | Tangens hyperbolicus |

Wie in der Tab. 5.3 dargestellt, wurden bei der Optimierung die Anzahl der verdeckten Schichten, die Aktivierungsfunktion in den verdeckten Schichten und die Anzahl der Neuronen in den verdeckten Schichten optimiert. Die Bayes'sche Optimierung hat als beste Konfiguration 18 Neuronen in 2 Schichten ergeben. Als Aktivierungsfunktion hat sich der Tangens hyperbolicus als beste Funktion herausgestellt.

### 5.5.2 Lernkurve

Zur Überprüfung des Trainings hinsichtlich Über- und Unteranpassung wird die Lernkurve analysiert. Wie in dem Kapitel 3.3.6 dargestellt, gibt die Kurve eine Möglichkeit die Anpassung des Modells zu erkennen. Die Abb. 5.5 zeigt die Lernkurve für das datenbasierte Modell des Auslegerzylinders.




Abbildung 5.5: Lernkurve des inversen datenbasierten Streckenmodells für den Auslegerzylinder

In der Abb. 5.5 wird der MSE über der Anzahl der Trainingsepochen gezeigt. Es ist zu erkennen, dass der Fehler zu Beginn stark sinkt und anschließend nur gering fällt. Die Abb. 5.5 zeigt, dass der

Fehler einen stabilen Zustand, sowohl auf dem Trainings- als auch auf dem Validierungsdatensatz annimmt. Der Fehler auf dem Validierungsdatensatz liegt außerdem leicht oberhalb des Fehlers auf dem Trainingsdatensatz. Dieser Verlauf ist wie in dem Kapitel 3.3.6 erklärt charakteristisch für eine gute Anpassung des Modells. Es kann davon ausgegangen werden, dass weder eine Über- noch eine Unteranpassung des Modells aufgetreten ist.

### 5.5.3 Ergebnisse auf dem Crossvalidierungsdatensatz

Neben den Untersuchungen der Optimierung und des Trainings ist es auch notwendig das Modell auf einem Crossvalidierungsdatensatz zu bewerten. Der Crossvalidierungsdatensatz ist ein Datensatz, welcher nicht für das Training des Modells verwendet wird und somit unbekannt für das Modell ist. Die Abb. 5.6 zeigt die Ergebnisse des Neuronalen Netzes auf einem Ausschnitt des Crossvalidierungsdatensatzes. Als Vergleichsmodell kommt das physikalisch motivierte Modell zum Einsatz.




Abbildung 5.6: Performance des Neuronalen Netzes auf dem Crossvalidierungsdatensatz

In der Abb. 5.6 wird als Referenz (blau) das applizierte Joysticksignal während der Datengenerierung gezeigt. Die Modelle schätzen anhand der gemessenen Ausgänge und Zustände des Streckenverhaltens das Joysticksignal. In der Abb. 5.6 ist eine Übereinstimmung des geschätzten Joysticksignals mit dem Referenzverlauf zu sehen. Wie in der Darstellung zu erkennen liefert das Neuronale Netz ein besseres Ergebnis als das physikalisch modellierte Modell. Auch die dynamischen Bereiche werden von dem Neuronalen Netz sehr gut abgedeckt. Hier ist der Vergleich mit dem physikalischen Modell jedoch nur bedingt möglich, da bei der theoretischen Modellierung nur der statische Zusammenhang abgebildet wurde. Die Dynamik ist theoretisch nur schwierig zu modellieren.

Neben der visuellen Analyse ist es notwendig das Modell, anhand der in dem Kapitel 5.4.1 vorgestellten Kennzahlen, zu analysieren. Die Bewertung mit diesen Kennzahlen wird in der Tab. 5.4 dargestellt. Es bestätigt sich das gleiche Ergebnis wie bereits in der Abb. 5.6. Alle Kennzahlen zeigen eine Verbesserung gegenüber dem physikalischen Modell.

Tabelle 5.4: Ergebnisse auf dem Crossvalidierungsdatensatz

| Kennzahl | Wert NN | Wert phy. Modell |
|----------|---------|------------------|
| RMSE     | 43      | 205              |
| MSE      | 0,019   | 0,42             |
| MAE      | 28      | 144              |
| R2       | 0,76    | 0,98             |

## 6 Validierung

Die bisher durchgeführten Analysen zeigen die Modellperformance nur auf gemessenen Validierungsdaten. Dies wird nachfolgend als offline Validierung bezeichnet. Im Vergleich zu der Realität (online Validierung) sind bei der online Validierung die Regressoren zusammenpassende Messgrößen. In dem realen Betrieb kommt es jedoch zu Rückkopplungseffekten, da ein Teil des Regressors vorgegeben wird und ein Teile gemessen wird. In dem modellbasierten Regler werden die Drücke gemessen und die Geschwindigkeit als Führungsgröße vorgegeben. Dadurch kann bei der offline Validierung nur näherungsweise abgeschätzt werden wie sich das Modell im Regler verhält. Um die nur zum Teil validen Aussagen der offline Untersuchungen zu validieren, wird der Regler auf dem Versuchsträger getestet und validiert. Bei den online Versuchen wird der Geschwindigkeitsregler nach der Abb. 6.1 verwendet.

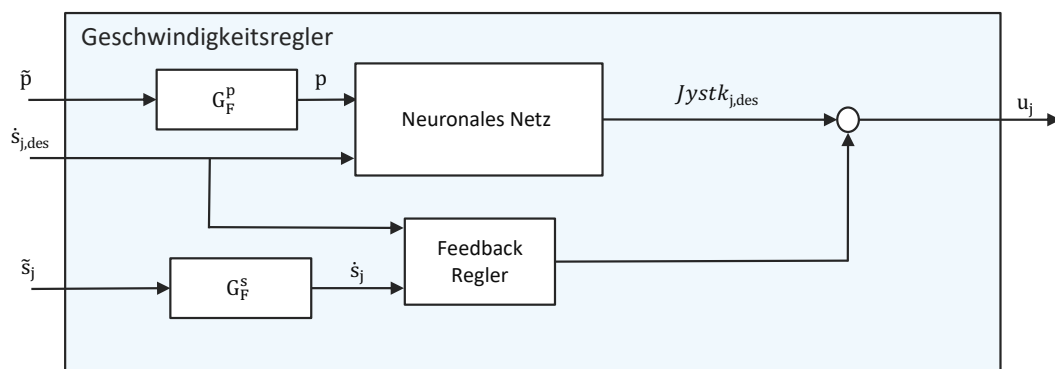


Abbildung 6.1: Blockschaltbild Reglerstruktur

Jeder Zylinder wird jeweils einzeln von einem separaten Regler angesteuert. Dabei gibt der Index  $j$  an um welchen Zylinder es sich handelt. Als Führungsgröße wird die Sollgeschwindigkeit vorgegeben. Dem Neuronalen Netz werden neben der Führungsgröße auch die zurückgeführten gemessenen Drücke  $\tilde{p}$  zugeführt. Die Drücke werden mit dem gleichen Filter  $G_F^p$  wie in der offline Datenvorbereitung (siehe Kapitel 4.3.2) gefiltert. Dies ist notwendig, um die gleiche Dynamik und Phasenverschiebung des Druckverlaufs (ähnlich zu den Trainingsdaten) zu erreichen. Aus den gefilterten Drücken  $p$  und der Sollgeschwindigkeit  $\dot{s}_{j,des}$  werden die Regressoren für das Modell bestimmt. Hierzu werden die Regressoren gewählt, welche die besten Ergebnisse bei der offline Validierung (siehe Kapitel 5.5) ergeben haben. Aus diesen Regressoren schätzt das NN den für den Zylinder  $k$  notwendigen Joystick  $Jystk_{j,des}$  um die Sollgeschwindigkeit  $\dot{s}_{j,des}$  zu erreichen. Parallel

zu dem Neuronalen Netz kommt ein Feedback-Regler (bestehend aus einem einfachen PI-Regler) zum Einsatz, um Störungen und Modellfehler zu kompensieren.

Die Güte des Reglers wird nachfolgend zunächst bei Einzelachsbewegungen untersucht um das stationäre Verhalten des Modells zu bewerten. Damit Aussagen über die Güte des Reglers getroffen werden können, werden die Ergebnisse mit dem bereits vorhanden physikalischen motivierten Regler verglichen. Anschließend wird das dynamische Verhalten bei Mehrachsbewegungen validiert. Für diese Mehrachsbewegungen wird die entwickelte Strategie für die Erstellung des datenbasierten Modells auf den Stielzylinder übertragen (siehe Anhang A1).

## 6.1 Physikalisch modellierter Regler

Als Referenz zu den Neuronalen Netzen kommt ein vorhandenes, physikalisch modelliertes Modell in der Regelung zum Einsatz. Dieses Referenzmodell wurde mit Hilfe von physikalischen Gleichungen anhand eines Simulationsmodells erzeugt. Das Modell wurde im Rahmen eines Projekts bei der Abteilung "Applied Robotics for Offroad and Offshore- von Bosch entwickelt. Bei diesem Projekt wurde zunächst das Verhalten des kompletten Baggers in AMESIM modelliert und daraus das inverse Streckenverhalten abgeleitet. Das inverse Modell wurde so entwickelt, dass es nur die statischen Nichtlinearitäten abbildet. Die dynamischen Zusammenhänge wurden teilweise vernachlässigt, da diese sehr aufwendig zu modellieren sind. Zur theoretische Modellierung dieser Effekte wären zusätzliche Sensoren am Bagger und weitere Informationen über die einzelnen Bauteile notwendig. Das entwickelte inverse Modell lässt sich in verschiedene Teilbereiche (wie in Abb. 6.2 zu sehen) unterteilen.




Abbildung 6.2: Modellstruktur des Kennfelds

Das inverse Verhalten wurde hierzu in die inverse Zylinderdynamik, das inverse Verhalten des hydraulischen Systems und dem inversen Verhalten der Betriebssteuerung aufgeteilt. Hierbei handelt es sich um Verhalten aus unterschiedlichen Domänen. Das inverse Verhalten wird durch eine Reihe von Kennfeldern in dem Regler appliziert, was zu einem großen zeitlichen Aufwand führt und keine einfache Übertragbarkeit auf einen anderen Bagger möglich macht. Auch war es notwendig die Kennfelder aufwendig für jeden einzelnen Zylinder zu erzeugen.

## 6.2 Einzelachsbewegung

Für die Bewertung des Zeitverhaltens wird der Regler für den Auslegerzylinder zunächst für Einzelachsbewegungen untersucht. Da die Trainingsdaten nur aus Einzelachsbewegungen bestehen ist zu erwarten, dass die Güte des Reglers bei reinen Auslegerbewegungen sehr gut ist. Der Regler wird hinsichtlich der bleibenden Regelabweichung und der Dynamik beim Anfahren des Zylinders untersucht. Hierfür wird ein gefilterter Geschwindigkeitssprung auf unterschiedliche Werte getestet. Der Sprung wird mit einem PT1-System gefiltert, um eine Solltrajektorie zu erzeugen. Die Abb. 6.3 zeigt beispielhaft die erzeugte Trajektorie für eine Sprung von 0 m/s auf 0,01 m/s.




Abbildung 6.3: Erzeugung der Solltrajektorie für den Einzelachsreglertest

Der Versuch soll zeigen wie gut das Modell statische Geschwindigkeiten abdecken kann. Und wie groß die bleibende Regelabweichung ist. Die Abweichung sollte möglichst gering sein, um den parallel geschalteten Feedback-Regler zu entlasten. Ist die bleibende Regelabweichung klein so kann der Feedback-Regler weniger aggressiv ausgelegt werden.

### 6.2.1 Kleine Geschwindigkeiten

In diesem Test wird der Regler für kleine Sollgeschwindigkeiten untersucht. Es werden sowohl positive als auch negative Geschwindigkeiten im Rahmen der Versuchsreihe überprüft. Positive Geschwindigkeiten entsprechen einem Heben des Arms und negative Werte einem Senken des Baggerarms. Die Betrachtung von beiden Richtungen ist notwendig, da das Zylinderverhalten wie in Kapitel 2.2.1 erklärt nicht symmetrisch ist. Weiterhin muss der Auslegerzylinder beim Heben des Baggerarms der Gewichtskraft entgegenwirken.

Die Abb. 6.4 zeigt die Ergebnisse der Untersuchungen. In den Diagrammen ist auf der y-Achse die Geschwindigkeit in m/s und auf der x-Achse die Zeit in s aufgetragen. Die Solltrajektorie der Geschwindigkeit wird in rot dargestellt. In den Diagrammen werden die Istgeschwindigkeiten des Auslegerzylinders für den Regler (mit dem im vorherigen Kapitel entwickelten inversen Streckenmodell) in grün dargestellt. Um eine Aussage über die Güte des Reglers zu treffen, wird als Vergleich der Regler mit dem physikalischen Modell in orange abgebildet. Die Istgeschwindigkeiten werden aus dem Positionssignal des Zylinders offline (wie in dem Kapitel 5 dargestellt) bestimmt.

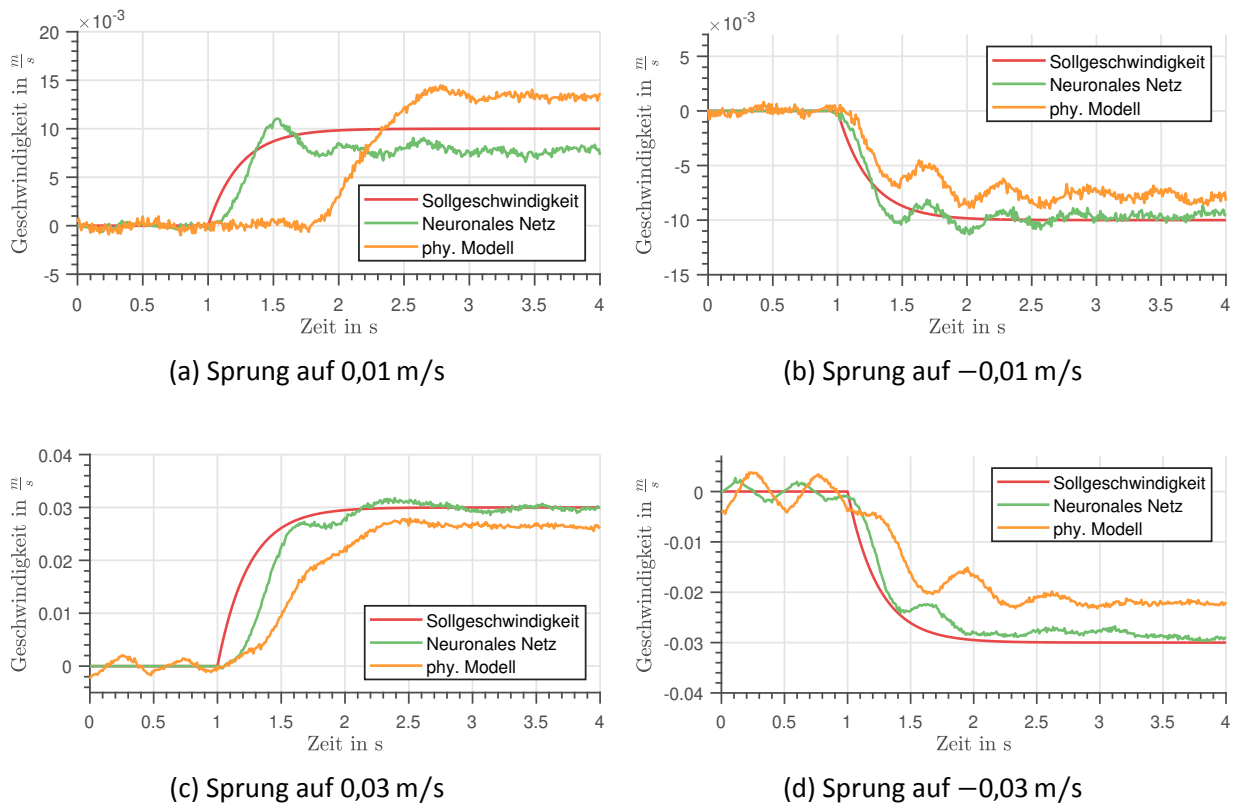


Abbildung 6.4: Regelverhalten bei kleinen Geschwindigkeiten

Vergleicht man die unterschiedlichen Geschwindigkeiten in der Abb. 6.4 untereinander so fällt auf, dass der Regler für die Geschwindigkeiten -0,01 m/s, 0,03 m/s und 0,03 m/s eine geringe Abweichung besitzt. Lediglich bei dem Sprung auf -0,01 m/s ist in der Abb. 6.4a ist zu erkennen, dass eine bleibenden Regelabweichung auftritt. Der Zylinder bewegt sich wie in der Abb. 6.4a zu sehen mit einer Geschwindigkeit von etwa 0,008 m/s. Wie bereits erwähnt, werden die Tests ohne parallel geschalteten Feedback-Regler durchgeführt. Dieser hat die Aufgabe die durch Modellfehler erzeugte Regelabweichung zu kompensieren.

## 6.2.2 Mittlere und große Geschwindigkeiten

Der Einsatz des modellbasierten Reglers wird auch bei mittleren und hohen Geschwindigkeiten untersucht. Die Versuche werden analog zu den Tests mit kleinen Geschwindigkeiten durchgeführt.

Die Abb. 6.5 zeigt die Regelperformance bei mittleren und hohen Geschwindigkeiten. Es ist zu sehen, dass die bleibende Regelabweichung für alle vier gezeigten Versuche gering ist.

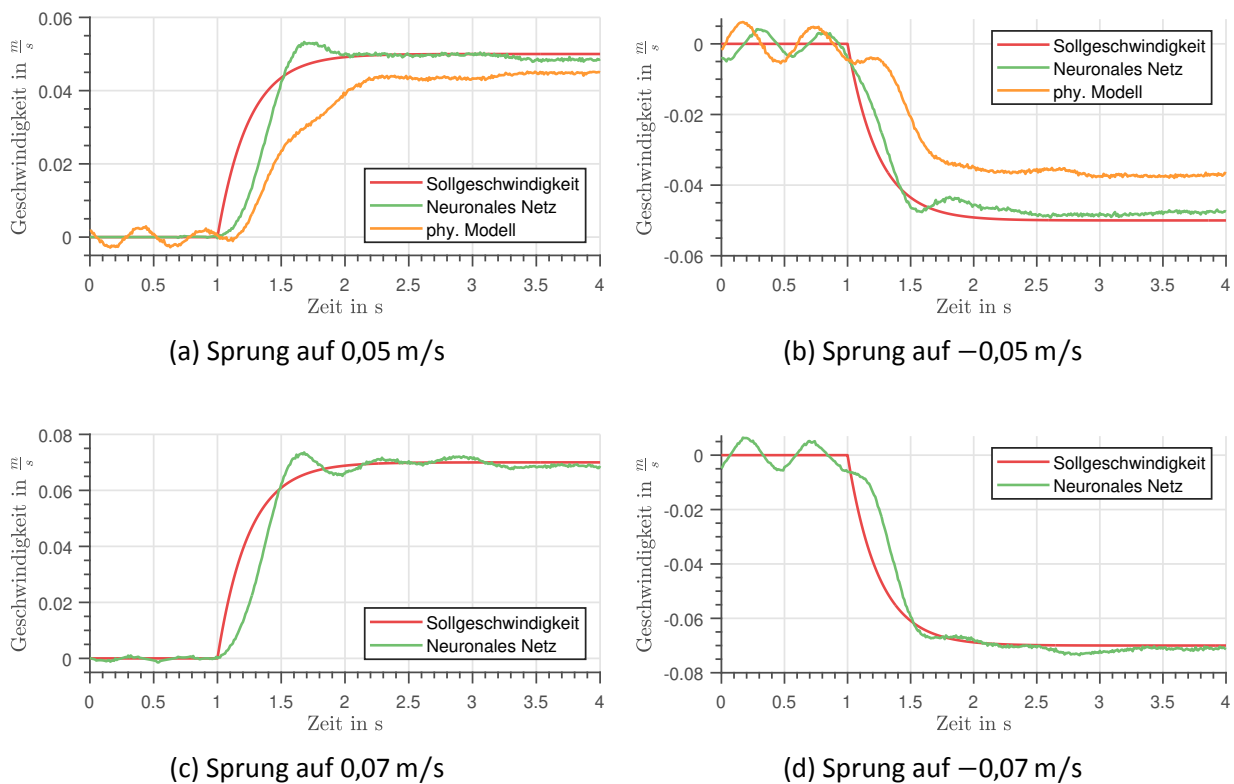


Abbildung 6.5: Regelverhalten bei mittleren und großen Geschwindigkeiten

Die vier Verläufe in der Abb. 6.5 zeigen eine schnelle Dynamik des Reglers auf. Diese gute Dynamik (im Vergleich zu dem physikalischen modellierten Regler) ist bedingt durch die Implementierung einer externen Dynamik in dem Neuronalen Netz (siehe Kapitel 5.2). Eine schnelle Dynamik wäre auch mit dem physikalischen Modell möglich, jedoch erhöht sich der Modellierungsaufwand immens. Die Modellierung aller Trägheiten im System stellt eine große Herausforderung dar. Im Gegensatz kann mit Hilfe des datenbasierten Ansatzes durch Hinzufügen der Beschleunigungen eine gute Dynamik erreicht werden, ohne den Aufwand für die Modellierung sehr zu erhöhen.

Bei den positiven Sprüngen in der Abb. 6.5a und Abb. 6.5c ist ein Überschwingen der Istgeschwindigkeit des Zylinders zu erkennen. Das Überschwingen ist im Verhältnis zu der stationären Sollgeschwindigkeit jedoch gering. In den beiden Abbildungen wird die gute Dynamik des Reglers deutlich. Die Istgeschwindigkeit erreicht nahezu gleichzeitig mit der Sollgeschwindigkeit den stationären Wert. Die bleibende Regelabweichung ist für die positive Geschwindigkeit 0,05 m/s und 0,07 m/s gering.

Im Vergleich zu den positiven Geschwindigkeiten tritt das Überschwingen des Zylinders bei negativen Sollgeschwindigkeiten nicht auf. Die Regelabweichung bei stationärem Sollwert ist gering und kann durch einen Feedback-Regler kompensiert werden. Hierfür kann ein einfacher PI-Regler



eingesetzt werden. Dieser kann durch das I-Glied die bleibende Regelabweichung kompensieren. Durch das Integrale Verhalten hat er jedoch die Eigenschaft ein langsamer Regler zu sein. Dieses Problem wird durch das dynamische Inverse Streckenmodell kompensiert [CHAC14].

Zusammenfassend hat die Einzelachsuntersuchung gezeigt, dass der datenbasierte Ansatz über den ganzen Arbeitsbereich nur geringe bleibende Regelabweichungen besitzt. Diese Abweichungen können ohne Probleme von einem einfachen Feedback-Regler kompensiert werden. Besonders ist auch die gute Dynamik des Reglers bei der Regelung auf die Sollwertfolge aufgefallen. Der Zylinder erreicht schnell die vorgegebenen Geschwindigkeiten.

### 6.3 Mehrachsbewegung mit externer Last

Um die Performance von modellbasierten Methoden auch bei Mehrachsbewegungen zu überprüfen, wird der Regler aus Abb. 6.1 in die überlagerte Struktur für das automatisierte Bewegen des Baggerarms implementiert. In der Abb. 6.6 ist die Implementierung des Geschwindigkeitsreglers gezeigt. Eine Erläuterung der Struktur ist in dem Kapitel 2.5.3 zu finden. In der Abbildung ist zu erkennen, dass zwei Geschwindigkeitsregler separat eingebaut werden. Die Unterteilung ist durch die Inverse Kinematik möglich. Diese berechnet sich aus der Geschwindigkeit  $\dot{x}_{e,des}$  des TCP die Zylinder Geschwindigkeiten  $\dot{s}_{Stiel,des}$  und  $\dot{s}_{Ausleger,des}$ . Den beiden Reglern werden außerdem noch die gemessenen Drücke  $\tilde{p}$  und Position  $\tilde{s}_{Stiel}$  und  $\tilde{s}_{Ausleger}$  zugeführt. Der Regler für den Stiel und Auslegerzylinder ist analog zu der Abb. 6.1 aufgebaut. Da bereits die bleibende Regelabweichung und das dynamische Verhalten des Neuronalen Netzes des Auslegerzylinders gezeigt wurde, wird für die Mehrachsbewegung der parallel geschaltete Feedback-Regler aktiviert.

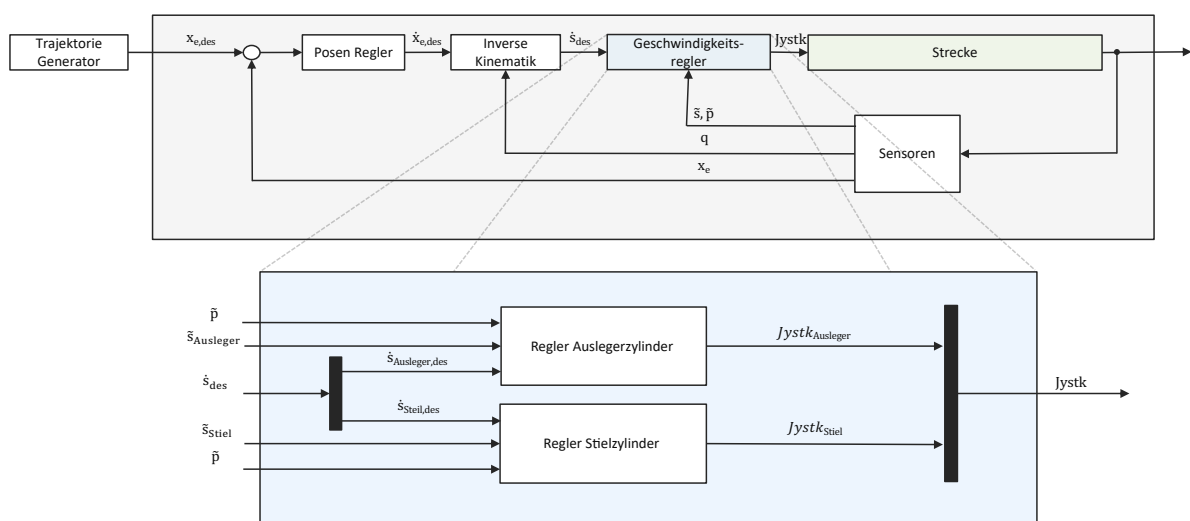


Abbildung 6.6: Überlagerte Reglerstruktur für autonome Bewegungen

Um die Übertragbarkeit der entwickelten Datengenerierung und Modellierungsmethode zu untersuchen, wird die Strategie des Auslegerzylinders auf den Stielzylinder übertragen. Mit Hilfe der Strategie war es möglich innerhalb von 2 Tagen die Daten zu generieren, ein Modell zu trainieren und anschließend das trainierte Modell in den Geschwindigkeitsregler des Stielzylinders zu implementieren. Dieser geringe zeitliche Aufwand verdeutlicht das Potential der datenbasierten Methoden und der Übertragbarkeit der entwickelten Strategie.

### 6.3.1 Ergebnisse beim Planieren

Für die Validierung des Reglers bei Mehrachsbewegungen wird von Trajektoriegenerator eine Bewegung des TCP auf einer Ebene vorgegeben. Dieser Vorgang wird auch als Planieren bezeichnet. Diese Trajektorie macht es notwendig den Stiel- und Auslegerzylinder zeitgleich zu bewegen. Bei ungeübten Operatoren stellt das Planieren eine Herausforderung dar. Daher steht dieser Vorgang auch als Assistenzfunktion zu Verfügung.

Die Funktion wird für den Versuch in feuchtem Sand durchgeführt. Durch den Sand kommt es zu einer externen Last auf die Schaufel, wodurch die Robustheit des Neuronalen Netzes überprüft wird. Die Abb. 6.7 zeigt den zeitlichen Verlauf der TCP-Position. Auf der y-Achse des Diagramms wird die Höhe in Meter und auf der x-Achse die Zeit in Sekunden angegeben.




Abbildung 6.7: Bewegung des TCPs bei dem Mehrachsreglertest

Neben der Sollhöhe des TCP wird in der Abb. 6.7 auch die Isthöhe in orange dargestellt. Aus der Abbildung ist zu erkennen, dass die maximale Abweichung etwa 3 cm ist. Diese Abweichung ist bezogen auf die Länge des Baggerarms ein geringer Fehler.

Die Differenz zwischen der Sollposition und Istposition wird dem Posenregler zugeführt und dieser berechnet die dafür notwendige Beschleunigung des TCPs. Über die Inverse Kinematik lässt sich

die Sollbeschleunigung des TCPs in Beschleunigungen der einzelnen Zylinder zerlegen. Die Abb. 6.8 zeigt die berechneten Sollgeschwindigkeitstrajektorien für den Stiel- und Auslegerzylinder für die in der Abb. 6.7 gezeigten Bewegung.

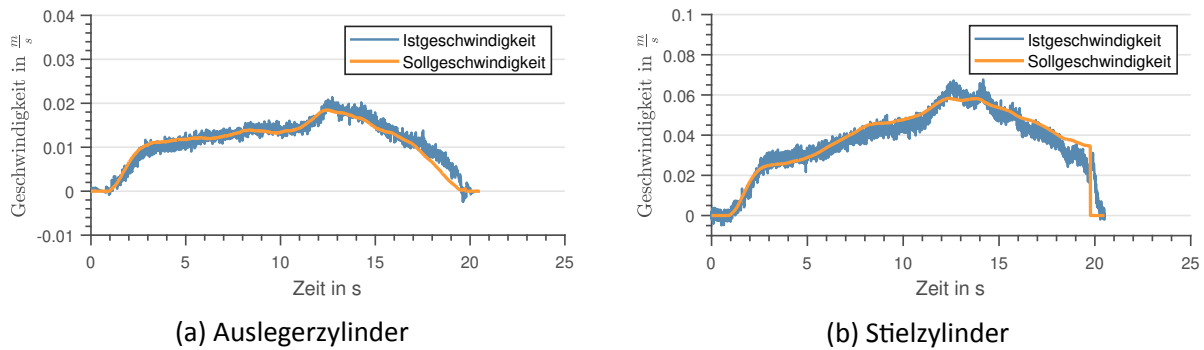


Abbildung 6.8: Geschwindigkeitsverlauf Planziehbewegung beim Reglertest

Die Abb. 6.8a zeigt den Geschwindigkeitsverlauf des Auslegerzylinders während des Planziehens. In der Abbildung ist die Sollgeschwindigkeit (orange) und die Istgeschwindigkeit (blau) dargestellt. Es ist zu sehen, dass der Ausleger der Sollgeschwindigkeitstrajektorie folgt. Wie bereits in dem vorherigen Abschnitt erläutert, zeigt der Regler eine hohe Güte in den dynamischen Bereichen. Wie in Abb. 6.8b zu sehen, folgt auch der Stielzylinder der vorgegeben Trajektorie. Vergleicht man den Verlauf mit dem Auslegerzylinder so ist zu erkennen, dass die Geschwindigkeiten deutlich höher sind. Bei dieser Bewegung hat der Auslegerzylinder die primäre Aufgabe, die Höhe des TCP einzustellen und der Stielzylinder die Bewegung in x-Richtung durchzuführen.

Zusammenfassend zeigt der Test geringe Abweichungen des TCPs. Diese sind auf die geringen Abweichungen zwischen der Sollgeschwindigkeit und Istgeschwindigkeit zurückzuführen. Außerdem wurde damit gezeigt, dass die Modelle die Regler auch Robust auf externe Kräfte (Grabkräfte durch den Sand) reagieren. Besonders ist hier zu betonen, dass die Regler mit Einzelachsbewegungen ohne externe Kräfte trainiert werden und dennoch gute Ergebnisse bei Mehrachsbewegungen haben. Diese Übertragbarkeit macht es einfacher die Daten zu generieren. Außerdem konnte mit dem Versuch auch eine Übertragbarkeit der entwickelten Strategie gezeigt werden. Der Fokus der Arbeit lag auf dem Auslegerzylinder und es war möglich die Entwickelte Strategie auf den Stielzylinder zu übertragen. Die Güte für den Stielzylinder (Abb. 6.8b) konnte innerhalb von nur zwei Tagen erreicht werden.

## 7 Fazit

Ziel dieser Arbeit war der Proof of Concept Nachweis der Machbarkeit von datenbasierten Methoden zur Regelung der Geschwindigkeit von hydraulischen Zylindern. Der Proof-of-Concept sollte an einem realen Versuchsträger untersucht werden. Zu diesem Zweck wurde eine Reihe von unterschiedlichen Testsignalen untersucht. Durch die Untersuchung mehrerer Anregungssignale an dem Auslegerzylinder, konnten die Auswirkungen der Anregungssignale auf die Modellierung gezeigt werden. Aus Sicht der Streuung der Messwerte zeigte das APRBS, im Vergleich zu dem Chirp Signal und der Sprunganregung, das beste Ergebnis. Die gesammelten Daten wurden anschließend zur Modellierung mit Hilfe von Neuronalen Netzen verwendet und in einer Regressorstudie analysiert. Die im Rahmen der Diplomarbeit entwickelte Toolbox hat es erlaubt, unterschiedliche Datensätze und Regressoren effizient miteinander zu vergleichen. Bei der Implementierung wurde darauf geachtet, dass das Modell für unterschiedliche Achsen und insbesondere Bagger eingesetzt werden kann. Die Untersuchungen mit offline Daten haben ergeben, dass ein Regressor bestehend aus der Druckdifferenz zwischen dem Pumpen- und Lastdruck, Druckdifferenz zwischen Kopf- und Pleuelldruck sowie der Geschwindigkeit und Beschleunigung des Zylinders die besten Ergebnisse geliefert hat. Es hat sich gezeigt das APRBS die besten Trainingsdaten für die Modellierung darstellen.

Die Ergebnisse der Reglertests haben schließlich gezeigt, dass das erzeugte Neuronale Netz auch auf dem realen Versuchsträger gute Ergebnisse liefert. Die quantitative Untersuchung des Geschwindigkeitsreglers für den Auslegerzylinder hat eine Reduzierung der bleibenden Regelabweichung, im Vergleich zu dem physikalisch modellierten Regler, gezeigt. Außerdem war es möglich eine Verbesserung der Anstiegszeit, durch die Abbildung der Dynamik mit externen Methoden bei Neuronalen Netz, zu erzielen. Gerade die Modellierung der Dynamik stellt bei der physikalischen Modellierung eine Herausforderung aufgrund der häufig nicht bekannten Trägheitsmomente dar. Die Übertragbarkeit der entwickelten Strategie wurde anhand von Untersuchungen an dem Stielzylinder validiert. Die Übertragbarkeit von einem Training mit Einzelachsbewegungen auf die Validierung bei Mehrachsbewegungen konnte im Rahmen von Untersuchungen der Planziehassistentenfunktion gezeigt werden. Sowohl der Stiel- als auch der Auslegerzylinder konnte der vorgegebenen Geschwindigkeitstrajektorie folgen. Weiterhin hat diese Untersuchung eine Stabilität hinsichtlich externer Störungen gezeigt, da der Versuch in Sand durchgeführt wurde. Anhand dieses Befundes kann darauf geschlossen werden, dass eine Übertragbarkeit der Strategie auf einen andern Bagger möglich ist. Zur Validierung dieser Aussage müssen entsprechend auf dieser Arbeit aufbauende Bemühungen darauf abzielen, die entwickelte Strategie an einem anderen Bagger zu testen und

zu validieren.

Der Fokus der Diplomarbeit lag auf dem gesamten Prozess von der Datengenerierung bis hin zu der Reglervalidierung auf dem realen Versuchsträger, daher konnte im Rahmen dieser Arbeit nicht genauer auf alternative datenbasierte Methoden eingegangen werden. Im Rahmen dieser Arbeit wurden jedoch eine Reihe von unterschiedlichen Datensätzen erzeugt, welche für weitere Untersuchungen genutzt werden können. Die Untersuchung von alternativen Modellen, auch im Hinblick auf die Grenzbereiche mit hoher Last, stellen bedeutende Aspekte für zukünftige Forschungen dar. Weiterhin stellt die Entwicklung einer Absicherungsstrategie der datenbasierten Methoden für einen sicheren Einsatz eine offene Entwicklung dar.

Abschließend ist festzuhalten, dass sich die datenbasierten Methoden zur Regelung von elektrohydraulischen Baggern eignen. Auch die Übertragbarkeit der Strategie konnte im Rahmen der Arbeit durch die Generierung eines Reglers für den Stielzylinder innerhalb von zwei Tagen gezeigt werden. Die Reduzierung des Arbeitsaufwandes von mehreren Monaten hinzu wenigen Tagen zeigt das Potential der datenbasierten Methoden zur Regelung von hydraulischen Baumaschinen.

# A1 Ergebnisse Modellierung Stielzylinder

Die Machbarkeit der datenbasierten Modellierung mit Neuronalen Netzen konnte für den Auslegerzylinder des Baggers gezeigt werden. Es ist möglich den Auslegerzylinder effektiv mit Hilfe von datenbasierten Modellen zu Regeln. Um eine Übertragbarkeit der entwickelten Strategie zu untersuchen, werden die Erkenntnisse auf den Stielzylinder übertragen. Die Ergebnisse werden nachfolgend kurz dargestellt.

## A1.1 Daten

Für die Anregung des Stielzylinders kommt das APRBS zum Einsatz, da dieses Signal sowohl bei der Visualisierung der Daten als auch bei der Performance des Modells am besten abgeschnitten hat. Bei den Versuchen wird der Auslegerzylinder konstant gehalten. Das Testsignal wird für drei Auslegerpositionen wiederholt. Die Abb. A1.1 zeigt die Verteilungen der Messwerte über dem Eingangssignal der Strecke.




Abbildung A1.1: Streudiagramme des Trainingsdatensatzes für den Stielzylinder

## A1.2 Netzstruktur

Für die Optimierung der Netzstruktur für den Stielzylinder kommt das in dem Kapitel 3.4.3 vorgestellte Verfahren der modellbasierte Bayesian Optimierung zum Einsatz. Weitere Details zu den

gewählten Hyperparametern ist dem Abschnitt 5.3 zu finden. Bei der Optimierung wurden 50 Iterationen durchgeführt. Die Optimierung hat die Parameter in der Tab. A1.1 ergeben.

Tabelle A1.1: Ergebnisse der Hyperparameteroptimierung für den Stielzylinder

| Hyperparameter                                 | Wert                 |
|--|----------------------|
| Anzahl an Neuronen in den verdeckten Schichten | 10                   |
| Anzahl an verdeckten Schichten                 | 1                    |
| Aktivierungsfunktionen                         | Tangens hyperbolicus |

### A1.3 Modellperformance

Nachfolgend wird das trainierte Modell für den Stielzylinder auf einem Crossvalidierungsdatensatz validiert. Die Abb. A1.2 zeigt die Ergebnisse des Modells für den Stielzylinder auf dem Validierungsdatensatz.




Abbildung A1.2: Lernkurve des inversen datenbasierten Streckenmodells für den Auslegerzylinder

In der oberen Abbildung wird als Referenz der gemessene Joystick während der Aufnahme der Daten dargestellt (blau). In der Darstellung wird das Joysticksignal des Stielzylinders über der Zeit

gezeigt. Als Vergleich dient das aufwändig, physikalisch modellierte Modell. Es ist in der Abb. A1.2 zu erkennen, dass die geschätzten Joystickwerte des Neuronale Netzes nur geringe Abweichungen zu der Referenz besitzen. Die untere Darstellung zeigt den Fehler zwischen der Referenz und dem Neuronalen Netz (in grün) und zwischen der Referenz und dem physikalischen Modell (in orange). Diese Abbildung verdeutlicht den geringen Fehler des Neuronalen Netzes im Vergleich zu dem physikalischen Modell.

Die Auswertung der Kennzahlen auf dem Crossvalidierungsdatensatz hat die Ergebnisse aus der Tab. A1.2 ergeben. In der Tabelle ist zu erkennen das alle Kennzahlen des Neuronalen Netzes bessere Ergebnisse als das physikalische Modell liefern.

Tabelle A1.2: Ergebnisse auf dem Crossvalidierungsdatensatz (Stielzylinder)

| Kennzahl | Wert NN | Wert phy. Modell |
|----------|---------|------------------|
| RMSE     | 43      | 205              |
| MSE      | 0,019   | 0,42             |
| MAE      | 28      | 144              |
| R2       | 0,76    | 0,98             |



# Literaturverzeichnis

- [Mat19] MathWorks: *Signal Processing: Take Derivatives of a Signal*. 2019.
- [ADAM18] ADAMY, Jürgen: *Nichtlineare Systeme und Regelungen*. Springer, 2018.
- [AHME10] AHMED, Nesreen K.; ATIYA, Amir F.; GAYAR, Neamat E. ; EL-SHISHINY, Hisham: An empirical comparison of machine learning models for time series forecasting. In: *Econometric Reviews* 29 (2010), Nr. 5-6, S. 594–621.
- [AKAI98] AKAIKE, Hirotugu: Autoregressive model fitting for control. In: *Selected Papers of Hirotugu Akaike*. Springer, 1998, S. 153–170.
- [ANZA11] ANZANELLO, Michel J.; FOGLIATTO, Flavio S.: Learning curve models and applications: Literature review and research directions. In: *International Journal of Industrial Ergonomics* 41 (2011), Nr. 5, S. 573 – 583. – ISSN 0169–8141.
- [BAMF19] BAMFORD: *JCB Hydradig*. <https://www.jcb.com/origin2017//asset/14/28413.ashx>: JCB North America, 2019.
- [BAUM16] BAUMANN, Thomas; FREBER, Philipp-Stephan; SCHÖBER, Kai-Stefan ; KIRCHNER, Florian: Bauwirtschaft im Wandel. In: *Trends und Potenziale bis 2020* (2016).
- [BEND16] BENDER, Frank A.: *Prädiktive Fahrermodelle zur Simulation und Teilautomatisierung eines Hydraulikbaggers*. Shaker Verlag, 2016.
- [BERG12] BERGSTRÄ, James; BENGIO, Yoshua: Random search for hyper-parameter optimization. In: *Journal of Machine Learning Research* 13 (2012), Nr. Feb, S. 281–305.
- [BEUC19] BEUCHER, Ottmar: *Signale und Systeme: Theorie, Simulation, Anwendung*. Springer Berlin Heidelberg, 2019.
- [BOHN16] BOHN, Christian; UNBEHAUEN, Heinz: *Identifikation dynamischer Systeme*. Springer Fachmedien Wiesbaden, 2016.
- [BRAD98] BRADLEY, David A.; SEWARD, Derek W.: The Development, Control and Operation of an Autonomous Robotic Excavator. In: *Journal of Intelligent and Robotic Systems* 21 (1998), Jan, Nr. 1, S. 73–97. – ISSN 1573–0409.
- [BRAM18] BRAMER, Max; PETRIDIS, Miltos: *Artificial Intelligence XXXV*. Springer, 2018.
- [CAND12] CANDELORO, Mauro; SØRENSEN, Asgeir J.; LONGHI, Sauro ; DUKAN, Fredrik: Observers for

- dynamic positioning of ROVs with experimental results. In: *IFAC Proceedings Volumes* 45 (2012), Nr. 27, S. 85–90.
- [CHAC14] CHACKO, V.; YU, H.; CANG, S. ; VLADAREANU, L.: State of the art in excavators. In: *Proceedings of the 2014 International Conference on Advanced Mechatronic Systems*, 2014, S. 481–488.
- [CHIN12] CHIN, Cheng; LAU, Michael: Modeling and testing of hydrodynamic damping model for a complex-shaped remotely-operated vehicle for control. In: *Journal of Marine Science and Application* 11 (2012), Nr. 2, S. 150–163.
- [CRAI09] CRAIG, John J.: *Introduction to robotics: mechanics and control*, 3/E. Pearson Education India, 2009.
- [DADH15] DADHICH, Siddharth: *A survey in automation of earth-moving machines*. Luleå tekniska universitet, 2015.
- [DEFL11] DEFLORIAN, Michael: *Versuchsplanung und Methoden zur Identifikation zeitkontinuierlicher Zustandsraummodelle am Beispiel des Verbrennungsmotors*, Technische Universität München, Diss., 2011.
- [DOHE97] DOHERTY, S. K.; B., Gomm J.: Experimentel Design Considerations for non-linear System Identification using Neural Networks. In: *Computers & chemical Engineering* (1997).
- [DUMI18] DUMITRESCU, Roman; GAUSEMEIER, Jürgen; SLUSALLEK, Philipp; CIESLIK, Sarah; DEMME, Georg; FALKOWSKI, Tommy; HOFFMANN, Hilko; KADNER, Susanne; REINHART, Felix; WESTERMANN, Thorsten ; WINTER, Johannes: Studie "Autonome Systeme". Berlin : Expertenkommission Forschung und Innovation (EFI), 2018 ( 13-2018). – Studien zum deutschen Innovationssystem.
- [DURI17] DURIEZ, Thomas; BRUNTON, Steven L. ; NOACK, Bernd R.: *Machine Learning Control-Taming Nonlinear Dynamics and Turbulence*. Springer, 2017.
- [EDGE03] EDGE, KA: On the control of electrohydraulic systems-some recent research contributions. In: *8th Scandinavian International Conference on Fluid Power*, 2003.
- [ERTE16] ERTEL, Wolfgang: *Grundkurs Künstliche Intelligenz*. Springer, 2016.
- [FINZ11] FINZEL, Robert: *Elektrohydraulische Steuerungssysteme für mobile Arbeitsmaschinen*. Shaker, 2011.
- [GATT11] GATTRINGER, Hubert: *Starr-elastische Robotersysteme*. Springer Berlin Heidelberg, 2011.
- [GEIM14] GEIMER, Marcus; POHLANDT, Christian: *Grundlagen mobiler Arbeitsmaschinen*. Bd. 22. KIT Scientific Publishing, 2014.
- [GOOD16] GOODFELLOW, Ian; BENGIO, Yoshua ; COURVILLE, Aaron: *Deep learning*. MIT press, 2016.

- [GUTJ12] GUTJAHR, Tobias: *Dynamic System Identification with Gaussian Processes in Model-Based Engine Development*, Technischen Universität Ilmenau, Diss., 2012.
- [HAGA94] HAGAN, Martin T.; MENHAJ, Mohammad B.: Training feedforward networks with the Marquardt algorithm. In: *IEEE transactions on Neural Networks* 5 (1994), Nr. 6, S. 989–993.
- [HEMA09] HEMAMI, Ahmad; HASSANI, Ferri: An overview of autonomous loading of bulk material. In: *26th International Symposium on Automation and Robotics in Construction*, 2009, S. 405–411.
- [HYND06] HYNDMAN, Rob J.; KOEHLER, Anne B.: Another look at measures of forecast accuracy. In: *International journal of forecasting* 22 (2006), Nr. 4, S. 679–688.
- [ISER05] ISERMANN, Rolf: *Mechatronic Systems: Fundamentals*. Springer Fachmedien Wiesbaden, 2005.
- [ISER10] ISERMANN, Rolf; MÜNCHHOF, Marco: *Identification of Dynamic Systems - An Introduction with Applications*. Berlin Heidelberg : Springer Science Business Media, 2010. – ISBN 978-3-540-78879-9.
- [JELA12] JELALI, Mohieddine; KROLL, Andreas: *Hydraulic servo-systems: modelling, identification and control*. Springer Science & Business Media, 2012.
- [JIMÉ07] JIMÉNEZ, Álvaro B.; LÁZARO, Jorge L. ; DORRONSORO, José R: Finding optimal model parameters by discrete grid search. In: *Innovations in Hybrid Intelligent Systems*. Springer, 2007, S. 120–127.
- [JORD92] JORDAN, Michael I.; RUMELHART, David E.: Forward models: Supervised learning with a distal teacher. In: *Cognitive science* 16 (1992), Nr. 3, S. 307–354.
- [KAAS96] KAASTRA, Ieabeling; BOYD, Milton: Designing a neural network for forecasting financial and economic time series. In: *Neurocomputing* 10 (1996), Nr. 3, S. 215–236.
- [KARL11] KARLIK, Bekir; OLGAC, A V.: Performance analysis of various activation functions in generalized MLP architectures of neural networks. In: *International Journal of Artificial Intelligence and Expert Systems* 1 (2011), Nr. 4, S. 111–122.
- [KAUT14] KAUTZMANN, Timo: *Die mobile Arbeitsmaschine als komplexes System*, Diss., 2014.
- [KELA14] KELASIDI, Eleni; PETTERSEN, Kristin Y. ; GRAVDAHL, Jan T.: A control-oriented model of underwater snake robots. In: *2014 IEEE International Conference on Robotics and Biomimetics (ROBIO 2014)* IEEE, 2014, S. 753–760.
- [KIŞI05] KIŞI, Özgür; UNCÜOĞLU, Erdal: Comparison of three back-propagation training algorithms for two case studies. (2005).
- [KLEI93] KLEIN, Andreas: *Einsatz der Fuzzy-Logik zur Adaption der Positionsregelung fluidtechni-*

*scher Zylinderantriebe.* na, 1993.

- [KLEI16] KLEIN, Aaron; FALKNER, Stefan; BARTELS, Simon; HENNIG, Philipp ; HUTTER, Frank: Fast bayesian optimization of machine learning hyperparameters on large datasets. In: *arXiv preprint arXiv:1605.07079* (2016).
- [KLÜV12] KLÜVER, Christina; KLÜVER, Jürgen ; SCHMIDT, Jörn: *Modellierung komplexer Prozesse durch naturanaloge Verfahren.* Springer Fachmedien Wiesbaden, 2012. – ISBN 9783834825100.
- [KOMS13] KOMSTA, Jan: *Nonlinear robust control of electrohydraulic systems.* VDI-Verlag, 2013.
- [KRIE07] KRIESEL, David. *Neuronale Netze.* 2007.
- [KRUS11] KRUSE, Rudolf; BORGELT, Christian; KLAWONN, Frank; MOEWES, Christian; RUSS, Georg; STEINBRECHER, Matthias [u. a.]: Computational Intelligence. In: *Vieweg+ Teubner* (2011), S. 139–151.
- [KUBA15] KUBAT, Miroslav: *An Introduction to Machine Learning.* Springer International Publishing, 2015.
- [KUNZ02] KUNZE: *Baumaschinen.* Vieweg+ Teubner Verlag, 2002.
- [LEVI18] LEVINE, William S.: *The Control Handbook (three volume set).* CRC press, 2018.
- [LJUN99] LJUNG, L.: *System Identification: Theory for the User.* Prentice Hall PTR, 1999 (Prentice Hall information and system sciences series). – ISBN 9780136566953.
- [LORE17] LORENZ, Sebastian; WAURICH, Volker; ANSORGE, Dieter; FRANKE, Ingmar S. ; KRZYWINSKI, Jens: Mobiles Bedienkonzept für die Baggersteuerung von Morgen. In: HESS, Steffen (Hrsg.); FISCHER, Holger (Hrsg.): *Mensch und Computer 2017 - Usability Professionals.* Regensburg : Gesellschaft für Informatik e.V., 2017.
- [LUNZ16] LUNZE, Jan: *Regelungstechnik 2.* Springer, 2016.
- [MACI02] MACIEJOWSKI, Jan M.: *Predictive control: with constraints.* Pearson education, 2002.
- [MAED13] MAEDA, Guilherme J.: *Learning and reacting with inaccurate prediction: applications to autonomous excavation,* University of Sydney, Diss., 2013.
- [MEYE14] MEYER, Martin: *Signalverarbeitung.* Springer Fachmedien Wiesbaden, 2014.
- [MURR12] MURRENHOFF, Hubertus: *Servohydraulik - geregelte hydraulische Antriebe.* 4. Aufl. Aachen : Inst. für Fluidtechnische Antriebe und Steuerungen, 2012. – ISBN 978–3–844–00947–7.
- [NARE12] NARENDRA, Kumpati S.; ANNASWAMY, Anuradha M.: *Stable adaptive systems.* Courier Corporation, 2012.
- [NELL13] NELLES, Oliver: *Nonlinear system identification: from classical approaches to neural net-*

- works and fuzzy models*. Springer Science & Business Media, 2013.
- [NGUY11] NGUYEN-TUONG, Duy; PETERS, Jan: Model learning for robot control: a survey. In: *Cognitive Processing* 12 (2011), Nov, Nr. 4, S. 319–340. – ISSN 1612–4790.
- [PEAR02] PEARSON, Ronald: Outliers in process modeling and identification. In: *IEEE Transactions on Control Systems Technology* 10 (2002), Jan, Nr. 1, S. 55–63. – ISSN 1063–6536.
- [PETK06] PETKOS, Georgios; TOUSSAINT, Marc ; VIJAYAKUMAR, Sethu: Learning multiple models of non-linear dynamics for control under varying contexts. In: *International Conference on Artificial Neural Networks* Springer, 2006, S. 898–907.
- [PETR14] PETRIČ, Tadej; GAMS, Andrej; ŽLAJPAH, Leon ; UDE, Aleš: Online learning of task-specific dynamics for periodic tasks. In: *2014 IEEE/RSJ International Conference on Intelligent Robots and Systems* IEEE, 2014, S. 1790–1795.
- [ROBE02] ROBERTS, Jonathan M.; DUFF, Elliot S. ; CORKE, Peter I.: Reactive navigation and opportunistic localization for autonomous underground mining vehicles. In: *Information Sciences* 145 (2002), Nr. 1, S. 127 – 146. – ISSN 0020–0255.
- [RUEC17] RUECKERT, Elmar; NAKATENUS, Moritz; TOSATTO, Samuele ; PETERS, Jan: Learning Inverse Dynamics Models in  $O(n)$  time with LSTM networks. In: *2017 IEEE-RAS 17th International Conference on Humanoid Robotics (Humanoids)* IEEE, 2017, S. 811–816.
- [SCHM10] SCHMIDT, Daniel; PROETZSCH, Martin ; BERNS, Karsten: Simulation and control of an autonomous bucket excavator for landscaping tasks. In: *2010 IEEE International Conference on Robotics and Automation* IEEE, 2010, S. 5108–5113.
- [SJÖB95] SJÖBERG, Jonas; ZHANG, Qinghua; LJUNG, Lennart; BENVENISTE, Albert; DELYON, Bernard; GLORENNEC, Pierre-Yves; HJALMARSSON, Håkan ; JUDITSKY, Anatoli: Nonlinear black-box modeling in system identification: a unified overview. In: *Automatica* 31 (1995), Nr. 12, S. 1691–1724.
- [SPON08] SPONG, Mark W.; VIDYASAGAR, Mathukumalli: *Robot dynamics and control*. John Wiley & Sons, 2008.
- [TAN01] TAN, Ai H.; GODFREY, Keith R.: The generation of binary and near-binary pseudo-random signals: An overview. In: *IMTC 2001. Proceedings of the 18th IEEE Instrumentation and Measurement Technology Conference. Rediscovering Measurement in the Age of Informatics (Cat. No. 01CH 37188)* Bd. 2 IEEE, 2001, S. 766–771.
- [VIDO16] VIDONI, R.; CARABIN, G.; GASPARETTO, A. ; MAZZETTO, F.: Stability Analysis of an Articulated Agri-Robot Under Different Central Joint Conditions. In: REIS, Luís Paulo (Hrsg.); MOREIRA, António P. (Hrsg.); LIMA, Pedro U. (Hrsg.); MONTANO, Luis (Hrsg.) ; MUÑOZ-MARTINEZ, Victor (Hrsg.): *Robot 2015: Second Iberian Robotics Conference*. Cham : Springer International Publishing, 2016. – ISBN 978–3–319–27146–0, S. 335–346.

- [VYAS19] VYAS, Jaidev; GOPALSAMY, Belamurugan ; JOSHI, Harshavardhan: *Electro-Hydraulic Actuation Systems Design Testing Identification and Validation*. Springer, 2019.
- [WANG11] WANG, Liuping; GARNIER, Hugues: *System Identification, Environmental Modelling, and Control System Design*. Springer, 2011.
- [WATT17] WATTER, Holger: *Hydraulik und Pneumatik*. Springer Fachmedien Wiesbaden, 2017.
- [WEIG17] WEIGAND, Jonas: *Systemidentifikation eines CNC-Bearbeitungszentrums mit Künstlichen Neuronalen Netzen*, RWTH Aachen University, Diplomarbeit, 2017.
- [WEIS95] WEISHAUPT, E; VOLKER, B: Energiesparende elektrohydraulische schaltungskonzepte. In: *Olhydraulik und Pneumatik* 39 (1995), Nr. 2, S. 106–112.
- [WILL15] WILL, Dieter; GEBHARDT, Norbert: *Hydraulik: Grundlagen, Komponenten, Systeme*. Springer-Verlag, 2015.
- [WOLP98] WOLPERT, Daniel M.; KAWATO, Mitsuo: Multiple paired forward and inverse models for motor control. In: *Neural networks* 11 (1998), Nr. 7-8, S. 1317–1329.
- [YU11] YU, Hao; WILAMOWSKI, Bogdan: Levenberg–Marquardt Training. In: *Intelligent Systems* (2011), 02, S. 1–16.
- [ZHU18] ZHU, Quanmin; NA, Jing ; WU, Xing: *Innovative Techniques and Applications of Modeling, Identification and Control: Selected and Expanded Reports from ICMIC'17*. Bd. 467. Springer, 2018.